

PROGRAMA DE PÓS-GRADUAÇÃO EM PRODUÇÃO VEGETAL

Israel Gomes Cruz

**AVALIAÇÃO DA EFICÁCIA DE CONTROLE DE PLANTAS DANINHAS POR
GLYPHOSATE COM USO DE ANÁLISE COMPUTACIONAL DE IMAGENS POR
*RANDOM FOREST***

**Montes Claros
2024**

Israel Gomes Cruz

**AVALIAÇÃO DA EFICÁCIA DE CONTROLE DE PLANTAS DANINHAS POR
GLYPHOSATE COM USO DE ANÁLISE COMPUTACIONAL DE IMAGENS POR
*RANDOM FOREST***

Dissertação apresentada ao Programa de Pós-Graduação em Produção Vegetal da Universidade Federal de Minas Gerais, como requisito parcial para a obtenção do título de Mestre em Produção Vegetal.

Orientador: Leonardo David Tuffi Santos

Coorientador: Alcinei Místico Azevedo

Montes Claros

2024

Cruz, Israel Gomes.

C957a
2024

Avaliação da eficácia de controle de plantas daninhas por glyphosate com uso de análise computacional de imagens por Random Forest [manuscrito] / Israel Gomes Cruz. Montes Claros, 2024.
96 f.: il.

Dissertação (mestrado) - Área de concentração em Produção Vegetal. Universidade Federal de Minas Gerais / Instituto de Ciências Agrárias.

Orientador: Leonardo David Tuffi Santos

Banca examinadora: Leonardo David Tuffi Santos, Alcinei Místico Azevedo, Luan Mateus Silva Donato, Matheus Mendes Reis.

Inclui referências: f. 21-34; f. 58-63; f. 89-94

1. Aprendizado do computador -- Teses. 2. Inteligência artificial -- Teses. 3. Modelos matemáticos -- Teses. 4. Herbicidas -- Teses. I. Santos, Leonardo David Tuffi. II. Universidade Federal de Minas Gerais. Instituto de Ciências Agrárias. III. Título.

CDU: 632



UNIVERSIDADE FEDERAL DE MINAS GERAIS
ICA - DIRETORIA

ATA DE DEFESA DE DISSERTAÇÃO

Aos 30 dias do mês de outubro do ano de dois mil e vinte e quatro, às 14:00 horas, sob a Presidência do Professor Leonardo David Tuffi Santos, D. Sc. (Orientador – UFMG/ICA) e com a participação dos Professores Alcinei Místico Azevedo, D. Sc. (Coorientador - UFMG/ICA), Matheus Mendes Reis, D. Sc. (IFNMG/Januária) e do Técnico Administrativo Luan Mateus Silva Donato, D. Sc. (UFMG), reuniu-se, presencialmente, a Banca de Defesa de Dissertação de Israel Gomes Cruz, aluno do Curso de Mestrado em Produção Vegetal. Após avaliação da defesa de Dissertação do referido aluno, a Banca Examinadora procedeu à publicação do resultado da defesa de Dissertação intitulada: “AVALIAÇÃO DA EFICÁCIA DE CONTROLE DE PLANTAS DANINHAS POR GLYPHOSATE COM USO DE ANÁLISE COMPUTACIONAL DE IMAGENS POR RANDOM FOREST”, sendo o aluno considerado aprovado. E, para constar, eu, Professor Leonardo David Tuffi Santos, Presidente da Banca, lavrei a presente ata que depois de lida e aprovada, será assinada por mim e pelos demais membros da Banca examinadora. OBS.: O aluno somente receberá o título após cumprir as exigências do ARTIGO 65 do regulamento do Curso de Mestrado em Produção Vegetal, conforme apresentado a seguir:

“Art. 65 Para dar andamento ao processo de efetivação do grau obtido, o candidato deverá, após a aprovação de sua Dissertação ou Tese e da realização das modificações propostas pela banca examinadora, se houver, encaminhar à secretaria do Colegiado do Programa, com a anuência do orientador, 1 (um) exemplar impresso e 1 (um) exemplar eletrônico da dissertação ou, tese, no prazo de 60 (sessenta) dias.”

Montes Claros, 30 de outubro de 2024.

Assinatura dos membros da banca examinadora:



Documento assinado eletronicamente por **Leonardo David Tuffi Santos, Professor do Magistério Superior**, em 30/10/2024, às 17:07, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alcinei Místico Azevedo, Vice diretor(a)**, em 30/10/2024, às 17:13, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Luan Mateus Silva Donato, Técnico em Agropecuaria**, em 30/10/2024, às 17:14, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Matheus Mendes Reis, Usuário Externo**, em 30/10/2024, às 17:20, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3685251** e o código CRC **AFACC6A0**.

AGRADECIMENTOS

A Deus, por ser a minha força e a minha fortaleza todos os dias.

À minha avó Nelita, pelos conselhos, ajuda e incentivo.

Aos meus pais, Janaina e Leonardo, pelo apoio e por torcerem sempre pelo meu sucesso.

À Sophia, pelo amor, carinho e apoio, estando ao meu lado sempre que preciso.

A todos os meus familiares e amigos que contribuíram para o sucesso desta caminhada.

Ao Prof. Leonardo Tuffi, pela orientação, ensinamentos, apoio e amizade.

Ao Prof. Alcinei Azevedo, pela coorientação, ensinamentos, apoio e amizade.

Aos membros do laboratório de Biologia e Manejo de Plantas Daninhas (ICA/UFMG) pela amizade, suporte e ajuda de mão de obra em todas as fases de implantação e obtenção de dados do experimento.

Ao Instituto de Ciências Agrárias da UFMG, pelos conhecimentos, suporte e estrutura oferecidos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão de bolsa e apoio financeiro.

À empresa KM Topografia, em especial aos senhores Alexandre, Moraci, Klauber e Denys pelo apoio na obtenção e processamento das imagens de drone.

“O Senhor com sabedoria lançou os fundamentos da terra; com inteligência estabeleceu os céus”

Provérbios 3:19 (Bíblia Sagrada, p. 712, 2017).

AVALIAÇÃO DA EFICÁCIA DE CONTROLE DE PLANTAS DANINHAS POR GLYPHOSATE COM USO DE ANÁLISE COMPUTACIONAL DE IMAGENS POR *RANDOM FOREST*

RESUMO

Um dos maiores desafios na produção agrícola é o manejo das plantas daninhas, que podem prejudicar a produtividade e viabilidade das lavouras. No manejo de plantas daninhas, podem ser utilizados diferentes métodos de controle, sendo o controle químico por herbicidas o mais difundido. Após a aplicação dos herbicidas, é realizada a análise da eficácia da sua ação. Essa análise é feita a partir da avaliação *in loco* por pessoa treinada, podendo se tornar um processo demorado, ineficiente e impreciso. Para atestar o controle, também é utilizado o método de coleta da massa vegetal remanescente, após a aplicação do herbicida, separando em material vivo e morto, o que possibilita o cálculo do controle. Este trabalho objetivou desenvolver modelos gerados por *Random Forest* capazes de avaliar a eficácia do controle de plantas daninhas pelo herbicida glyphosate a partir de imagens obtidas por *smartphone* e por drones (em quatro diferentes alturas). As imagens foram obtidas em área com infestação uniforme de *U. brizantha* dessecada por glyphosate com as doses 0, 144, 288, 576, 864, 1152 e 1440 g e.a. ha⁻¹. Usou-se 27 índices de vegetação como variáveis de entrada para o modelo, a fim de se estimar o controle com base nos dados da avaliação visual humana e nos dados de controle determinado pela massa vegetal morta pelo herbicida. Os modelos propostos foram avaliados pelo coeficiente de determinação de Pearson (r^2). O primeiro artigo considerou as imagens obtidas por *smartphone*, com os modelos desenvolvidos apresentando r^2 maior que 90% para as amostras de treinamento e validação, sendo capazes de prever com alta precisão o nível de controle das plantas daninhas pelo glyphosate. Os modelos foram robustos contra o *overfitting*, mostrando seu potencial de uso em novos conjuntos de dados. O segundo artigo utilizou as imagens de drone e os modelos desenvolvidos também apresentaram alta precisão nas previsões ($r^2 > 90\%$), para todas as amostras de treinamento e validação, independente da altura de voo. O modelo desenvolvido para avaliar o controle independente da altura também alcançou alta precisão e alto desempenho nas amostras de validação (r^2 maior que 90%), possibilitando o uso de imagens que variem em altura de voo e/ou qualidade da imagem (dentro da faixa de alturas testada). O uso de câmeras comuns foi suficiente para alcançar os objetivos do trabalho, o que significa maior economia e acessibilidade do processo em relação ao uso de câmeras especiais. O trabalho apresenta uma nova alternativa de avaliação do controle de plantas daninhas, com a possibilidade de implementação desses modelos em aplicativos móveis e *desktop*.

Palavras-chave: aprendizado de máquina, inteligência artificial, índices de vegetação, herbicida.

EVALUATION OF THE WEED CONTROL EFFICACY WITH GLYPHOSATE USING COMPUTATIONAL IMAGE ANALYSIS WITH RANDOM FOREST

ABSTRACT

One of the biggest challenges in agricultural production is the management of weeds, which can harm crop productivity and viability. Different control methods can be used in weed management, with chemical control using herbicides being the most widespread of them. After applying the herbicides, an analysis of the efficacy of their action is carried out. This analysis is carried out based on an on-site evaluation by a trained person, which can be a time-consuming, inefficient, and imprecise process. To confirm the control the method of collecting the remaining plant mass after applying the herbicide is also used, separating it into living and dead material, which makes it possible to calculate the control. This study aimed to develop models generated by Random Forest capable of evaluating the efficacy of weed control by the herbicide glyphosate based on images obtained by smartphone and drones (at four different heights). The images were obtained in an area with uniform infestation of *U. brizantha* desiccated by glyphosate doses of 0, 144, 288, 576, 864, 1152 and 1440 g a.e. ha⁻¹. Twenty-seven vegetation indices were used as input variables for the model, in order to estimate control based on data from human visual evaluation and control determined by plant mass killed by the herbicide. The proposed models were evaluated using the Pearson's coefficient of determination (r^2). The first article considered the images obtained by smartphone, with the developed models presenting r^2 greater than 90% for the training and validation samples, being able to predict with high accuracy the level of weed control by glyphosate. The models were robust against overfitting, showing their potential for use in new data sets. The second article used the drone images, and the developed models also presented high accuracy in predictions ($r^2 > 90\%$), for all training and validation samples, regardless of flight height. The model developed to evaluate control independently of height also achieved high accuracy and high performance in the validation samples (r^2 greater than 90%), allowing the use of images that vary in flight height and/or image quality (within the range of heights tested). The use of common cameras was sufficient to achieve the study objectives, which means greater economy and accessibility of the process compared to the use of special cameras. The study presents a new alternative for evaluating weed control, with the possibility of implementing these models in mobile and desktop applications.

Keywords: machine learning, artificial intelligence, vegetation indices, herbicide.

SUMÁRIO

1. INTRODUÇÃO	11
2. OBJETIVOS	13
2.1. Objetivo Geral	13
2.2. Objetivos Específicos	13
3. REVISÃO DE LITERATURA	14
3.1. Importância do manejo das plantas daninhas	14
3.2. Controle químico de plantas daninhas e o uso do glyphosate	15
3.3. Métodos tradicionais de avaliação do controle de plantas daninhas	16
3.4. RPAs (Aeronaves Remotamente Pilotadas).....	17
3.5. Análise de imagens na agricultura	18
3.5.1. Índices de vegetação	18
3.5.2. Segmentação, extração de características e classificação	19
REFERÊNCIAS	21
4. ARTIGOS	35
4.1. Artigo 1 - Uso de imagens de <i>smartphone</i> na avaliação do controle de plantas daninhas por glyphosate: uma abordagem computacional por <i>Random Forest</i>	35
4.2. Artigo 2 - Análise computacional de imagens de drones na avaliação do controle de plantas daninhas por glyphosate	64
5. CONSIDERAÇÕES FINAIS	95

1. INTRODUÇÃO

Um dos maiores desafios na produção agrícola é o manejo das plantas daninhas. Essas plantas competem com a cultura principal por água, luz e nutrientes, além de outros efeitos negativos não relacionados à competição (Anuch Tiranti; Curti; Acreche, 2025; Li; Denich, 2024; Venkataraju *et al.*, 2023), o que faz com que uma parcela considerável da produção agrícola mundial seja perdida devido à presença de plantas daninhas nas lavouras (Oerke, 2006; Gharde *et al.*, 2018; Chauhan, 2020).

O principal método utilizado para o controle de plantas daninhas é o controle químico por herbicidas, sendo o glyphosate o herbicida mais utilizado mundialmente (Benbrook, 2016; Novotny, 2022). No Brasil, o glyphosate também é o mais utilizado, com 266,09 mil toneladas vendidas no país apenas no ano de 2022, representando 33,23% do mercado de agrotóxicos e 54,04% do mercado de herbicidas brasileiro (IBAMA, 2025). Soma-se a isso o crescimento da área agrícola brasileira, que aumentou 78% nos últimos quarenta anos (Spadotto; Gomes, 2021), o que aumenta a demanda por esses produtos.

O uso de herbicidas de forma racional tem ganhado cada vez mais destaque global, a fim de se evitar problemas agrônômicos, como redução da diversidade de plantas, deriva em áreas vizinhas e seleção de plantas resistentes (Strehlow *et al.*, 2020) e problemas ambientais, como contaminação de corpos d'água, toxicidade para microbiota do solo, resíduos na cadeia alimentar e contaminação de humanos e animais (Das *et al.*, 2024).

Como parte do cronograma da adoção do controle químico com herbicidas, alguns dias após a aplicação dos produtos, é realizada a análise da eficácia de sua ação, sendo essa etapa essencial para o programa de manejo integrado de plantas daninhas (Oliveira *et al.*, 2024). Essa análise é feita a partir da avaliação visual do controle das plantas por pessoa treinada, sendo atribuída uma nota de 0 (zero) a 100% de acordo com os sintomas de intoxicação que a planta apresenta, em que 0 (zero) significa nenhum dano visível e 100 representa a morte da planta (Frans, 1972; SBCPD, 1995; Ghimire *et al.*, 2023). Para atestar o controle, também é utilizado o método de coleta da massa vegetal remanescente após a aplicação do herbicida, coletando amostras da parte aérea das plantas e separando-as em massa viva e massa morta, sendo possível o cálculo da porcentagem de material controlado pelo herbicida (Oliveira *et al.*, 2024).

Entretanto, o primeiro método de avaliação da eficácia descrito e atualmente mais utilizado é baseado puramente na avaliação visual, sendo ainda totalmente manual, o que pode torná-lo demorado, ineficiente e impreciso. O segundo método é bastante trabalhoso e demorado, além de demandar equipamentos específicos que exigem mão de obra qualificada para sua operação, como a estufa de ventilação forçada.

Uma possível alternativa a esses métodos tradicionais para a avaliação do controle de plantas daninhas é o uso de inteligência artificial (IA) e índices de reflectância da vegetação na análise de imagens capturadas com dispositivos como *smartphones* e Aeronaves Remotamente Pilotadas (RPAs, do inglês *Remotely Piloted Aircraft*), popularmente conhecidas como drones.

No cenário da agricultura de precisão, a análise computacional de imagens com IA têm sido uma ferramenta importante para a agricultura na automação e otimização de seus processos (Sow *et al.*, 2024; Ram *et al.*, 2024), utilizando inclusive imagens de drone e *smartphone* para fins como detecção de plantas de interesse em meio à presença de plantas daninhas (Moazzam *et al.*, 2023), para acompanhamento e estimativa da produtividade agrícola (Marconi *et al.*, 2024), para identificação de plantas daninhas (Dang *et al.*, 2023) e para estimativa de óleo essencial em frutos (Anello *et al.*, 2024).

Dentre os diversos algoritmos de IA, se destaca o *Random Forest* (RF), um algoritmo de aprendizado de máquina, que classifica conjuntos com uso de múltiplas árvores de decisão independentes e consegue lidar bem com grandes volumes de dados, *outliers* e ruído, além de ser flexível, eficiente e robusto contra o *overfitting* (Setargie *et al.*, 2023; Aria; Cuccurullo; Gnasso, 2021; Belgiu; Drăgu, 2016; Zaimes; Gounaridis; Symeonakis, 2019). O RF tem sido utilizado frequentemente em trabalhos de análise computacional de imagens na agricultura, como para identificação de espécies de plantas daninhas (Mkhize *et al.*, 2023), para análise da fertilidade do solo (Shahare *et al.*, 2024), para avaliação de sistemas de manejo de plantas daninhas (Caras *et al.*, 2024), e até para mapear os pontos de maior risco e os elementos que influenciam a presença de metais pesados em solos agrícolas (Xu *et al.*, 2024).

Portanto, este trabalho objetiva desenvolver modelos gerados por *Random Forest* capazes de avaliar a eficácia do controle de plantas daninhas por glyphosate, com índices de vegetação como variáveis de entrada, por meio de imagens obtidas por *smartphone* e por drones.

2. OBJETIVOS

2.1. Objetivo Geral

Objetivou-se desenvolver modelos gerados por inteligência artificial (IA) com o algoritmo *Random Forest* para a avaliação da eficácia do controle de plantas daninhas pelo herbicida glyphosate a partir de imagens obtidas por *smartphone* e por drones.

2.2. Objetivos Específicos

- Saber se o uso de imagens capturadas por câmeras comuns (RGB) de *smartphone* é suficiente para a avaliação eficiente de controle de plantas daninhas pelo herbicida glyphosate;
- Saber se o uso de imagens capturadas por câmeras comuns (RGB) obtidas por drones é suficiente para a avaliação eficiente de controle de plantas daninhas pelo herbicida glyphosate;
- Verificar se diferentes altitudes de voo do drone influenciam na eficiência das avaliações de controle de plantas daninhas;
- Identificar os índices de vegetação mais importantes para este estudo.

3. REVISÃO DE LITERATURA

3.1. Importância do manejo das plantas daninhas

Plantas daninhas são plantas indesejadas em uma determinada atividade humana, principalmente nas atividades agrícolas. Essas plantas também podem ser uma “praga quarentenária”, termo usado para toda espécie que, mesmo sob controle permanente, é considerada uma ameaça à atividade agrícola da região (Silva *et al.*, 2021). Até mesmo uma planta cultivada pode ser considerada daninha caso ocorra na área de outra cultura de interesse, sendo passível de controle, como a ocorrência do milho no cultivo de soja e da aveia em lavouras de trigo. No entanto, uma mesma planta pode ser considerada daninha se sua interferência for negativa ou pode ser considerada útil em situações que essa planta contribua para o controle da erosão, possa ser usada com fins medicinais, etc. (Silva *et al.*, 2007a).

As plantas daninhas podem se tornar um problema por competirem por recursos essenciais às plantas cultivadas como água, luz e nutrientes. Além disso, podem ser prejudiciais por abrigar pragas e doenças e por liberarem substâncias alelopáticas que afetam negativamente a cultura de interesse, interferindo significativamente na sua produtividade e na lucratividade da produção (Galon *et al.*, 2023; Galon *et al.*, 2017; Macías; Mejías; Molinillo, 2019; Gomes *et al.*, 2010). A alelopatia é um fenômeno biológico em que um organismo produz substâncias químicas para afetar o crescimento, sobrevivência, desenvolvimento e reprodução de outros organismos (Cheng; Cheng, 2015).

Plantas daninhas têm grande capacidade adaptativa e competitiva em diversos tipos de ambientes, mesmo em situações de estresse, como alta temperatura e umidade e estabelecimento em solos compactados e de acidez elevada, garantindo vantagens decisivas na competição pelos recursos com as plantas de interesse (Sousa; Sousa, 2024; Fernandes *et al.*, 2021).

Campos *et al.* (2023) encontraram que a convivência com plantas daninhas não controladas (nesse caso uma comunidade de plantas infestantes composta predominantemente por plantas eudicotiledôneas, que representavam 70% da comunidade infestante, e plantas monocotiledôneas, com 30%, distribuídas em sete famílias e dez espécies diferentes) reduziu em 90% a produtividade do feijão-caupi (*Vigna unguiculata* (L.) Walp.). Reginaldo *et al.* (2021) observaram perdas de até 98%

na produtividade de uma área de cultivo de cenoura (*Daucus carota* L.) infestada por plantas daninhas não controladas, perdas explicadas principalmente pela interferência do capim-colchão (*Digitaria horizontalis* Willd). Galon *et al.* (2021) encontraram perdas de mais de 90% da cultura do trigo infestada por azevém (*Lolium multiflorum*) e nabo (*Raphanus raphanistrum* e *R. sativus*) quando nenhum método de controle é utilizado. Piccinini *et al.* (2018) verificaram até 45% de perda na produtividade de soja infestada por espécies de corda-de-viola (*Ipomoea triloba* e *I. purpurea*).

Esses trabalhos mostram exemplos da agressividade e capacidade competitiva das plantas daninhas frente às plantas de interesse, sendo essencial que haja o melhor controle possível das plantas daninhas, a fim de se evitar a perda de produtividade e lucratividade da produção agrícola. Esse controle pode ser realizado por meio de diferentes métodos, sendo os principais o mecânico, o químico, o biológico, o físico e o cultural (Sousa; Sousa, 2024). Entre eles, o controle químico é o método mais utilizado para o controle de plantas daninhas, devido à sua eficiência e praticidade (Albrecht *et al.*, 2021).

3.2. Controle químico de plantas daninhas e o uso do glyphosate

O controle químico de plantas daninhas se baseia na aplicação de herbicidas para eliminar ou reduzir a interferência dessas plantas na área de interesse (Okumu; Vorster; Reinhardt, 2019; Nascimento *et al.*, 2024). Esses herbicidas podem ser seletivos, quando agem apenas contra determinadas plantas, não afetando a cultura de interesse (Lukangila *et al.*, 2024) ou não seletivos, quando afetam qualquer planta atingida (Grillo *et al.*, 2014, Oliveira Júnior *et al.*, 2021). Os herbicidas podem ser aplicados em pré-emergência, sobre o solo, antes da emergência das plantas daninhas e/ou da cultura principal (Ruiz *et al.*, 2025), ou em pós-emergência, após a emergência das plantas daninhas, para controlar indivíduos já estabelecidos (Wiederhecker *et al.*, 2024).

Os herbicidas também se dividem em herbicidas sistêmicos e não sistêmicos (conhecidos como herbicidas de contato). Um herbicida é considerado sistêmico quando pode se translocar via floema ou via floema e xilema, podendo assim se movimentar com liberdade na planta, enquanto um herbicida de contato atua somente no local onde entra em contato e penetra nas plantas, não tendo capacidade de se mover livremente por ela (Silva *et al.*, 2007b, Markus *et al.*, 2021).

Entre as inúmeras moléculas usadas para o controle químico de plantas daninhas, o glyphosate merece destaque. O glyphosate é um herbicida não seletivo e sistêmico, usado no controle de plantas daninhas e também na dessecação de culturas (Codognoto *et al.*, 2021; Christoffoleti; López-Ovejero, 2003). O glyphosate atua na rota do chiquimato, inibindo a enzima EPSPS (5-enol-piruvil-chiquimato-3-fosfato sintase), por competição com o substrato PEP (fosfoenolpiruvato), evitando a formação do corismato (Silva *et al.*, 2007b; Cardinali *et al.*, 2010). Com isso, há redução acentuada de fenilalanina, tirosina e triptofano nas plantas tratadas, aminoácidos essenciais para as plantas (Silva *et al.*, 2007b).

Plantas tratadas com glyphosate têm seu crescimento paralisado e os principais sintomas de intoxicação podem ser observados a partir de sete dias após a aplicação (7 DAA), como murcha, clorose e enrolamento foliar, além de necrose e senescência foliar, resultando na morte da planta (Tuffi Santos *et al.*, 2009; Costa *et al.*, 2020).

O uso do glyphosate deve ser feito de forma racional, devido ao potencial de danos ao meio ambiente, principalmente quando mal manejado, como alteração metabólica em comunidades microbianas (Aldehoff *et al.*, 2025), impacto em vegetação não alvo e em seu bioma associado (López-Chávez *et al.*, 2023), contaminação do solo e comprometimento de plantas não alvo (Soares *et al.*, 2019; Bemelmans *et al.*, 2024), impactos na saúde humana, especialmente de trabalhadores rurais que trabalham com sua aplicação, mesmo com boa adesão ao uso de equipamentos de proteção individual (Porru *et al.*, 2024) e contaminação de água potável (Nunes *et al.*, 2024). Tendo em vista esses possíveis problemas, o manejo do glyphosate deve ser feito correta e eficientemente, a fim de se evitar riscos ao meio ambiente e à saúde humana.

3.3. Métodos tradicionais de avaliação do controle de plantas daninhas

Após a aplicação dos herbicidas utilizados, é necessário fazer a avaliação da eficácia do controle químico. O método tradicional e atualmente mais utilizado consiste na avaliação visual do controle das plantas por pessoa treinada, sendo atribuída uma nota de 0 (zero) a 100%, de acordo com os sintomas de intoxicação que a planta apresenta, em que 0 (zero) significa nenhum dano visível e 100 representa a morte da planta (Frans, 1972; ALAM, 1974; SBCPD, 1995; Ghimire *et al.*, 2023).

Também é possível avaliar os sintomas de intoxicação nas plantas com o uso da escala de notas visuais proposta pelo *European Weed Research Council* – EWRC

(1964). Essa escala varia de 1 a 9, em que 1 representa ausência de sintomas e 9 a morte total da planta (Scherer *et al.*, 2017; Chiconi *et al.*, 2022).

Além desses métodos visuais, existe o método de avaliação de controle pela massa vegetal remanescente após o tratamento herbicida. Nesse método, amostras da parte aérea das plantas são coletadas e separadas em material vivo e morto, sendo depois levadas à estufa de ventilação forçada para secagem a 65°C por 72 horas. Assim, após pesar-se a massa seca desses materiais, é possível calcular o controle realizado pelo herbicida (Oliveira *et al.*, 2024).

3.4. RPAs (Aeronaves Remotamente Pilotadas)

A agricultura de precisão é definida como o gerenciamento da variabilidade espacial e temporal com o objetivo de aumentar os retornos econômicos e minimizar os efeitos negativos no meio ambiente (Pedersen *et al.*, 2004) e é comumente associada ao uso de tecnologia de ponta na agricultura, com uso de sensores, sistemas de posicionamento globais, câmeras, equipamentos modernos e softwares sofisticados, o que possibilita a obtenção e análise de dados estratégicos para a agricultura (Busse *et al.*, 2014; Jensen *et al.*, 2012; Pedersen *et al.*, 2004)

Nesse cenário, as RPAs (Aeronaves Remotamente Pilotadas), popularmente conhecidas como drones, tornaram-se grandes aliadas para a agricultura de precisão, por possuírem capacidade de capturar imagens que fornecem dados precisos e possibilitam a análise de variáveis importantes para a agricultura (Ampatzidis; Partel; Costa, 2020). Esses equipamentos têm sido usados para diversos fins na agricultura, como monitoramento do crescimento do açafrão (Nazeer *et al.*, 2024), para avaliação do estado nutricional e hídrico de plantas (Salazar-Reque *et al.*, 2023), mapeamento e detecção de plantas (Amarasingam *et al.*, 2024) e estimativa de rendimento da produção agrícola (Gade *et al.*, 2025).

Em específico ao manejo das plantas daninhas, os drones têm sido usados em diversos objetivos, como para aplicar e avaliar o volume ideal de pulverização de herbicidas para dessecação de plantas (Carneiro *et al.*, 2024; Pranaswi *et al.*, 2024), para identificação de plantas daninhas na lavoura (Cui *et al.*, 2024), para monitoramento de sistemas de manejo de daninhas (Caras *et al.*, 2024), para avaliar e mapear plantas daninhas em relação à cultura de interesse (Su *et al.*, 2022) e para melhorar a precisão de aplicação de herbicidas (Asad e Bais, 2020).

Quando equipados com câmeras especiais, como as multi e hiperespectrais, podem obter informações mais específicas e precisas, como a detecção precoce de doenças (Yu *et al.*, 2021; Zeng *et al.*, 2024) e de estresse hídrico (Chakhvashvili *et al.*, 2024). Sensores como o LiDAR (*Light Detection and Ranging*), embarcados em drones, também permitem a obtenção de dados detalhados, possibilitando extrair informações detalhadas e precisas em 3D do terreno (Lin; Habib, 2021) e usos como a avaliação detalhada do estado de distúrbio em ecossistemas florestais (Iheaturu *et al.*, 2024) e estimativa de estoques acumulados de carbono em locais agrícolas (Revenga *et al.*, 2024). No entanto, o alto custo desses equipamentos especiais acaba limitando seu uso para muitos produtores.

3.5. Análise de imagens na agricultura

3.5.1. Índices de vegetação

Uma importante ferramenta na análise de imagens agrícolas são os índices de vegetação. Índices de vegetação são fórmulas matemáticas que relacionam as bandas espectrais com o objetivo de realçar características específicas da vegetação. Eles permitem a avaliação e quantificação de atributos das plantas, a partir da análise da reflectância de diferentes bandas, como as do vermelho, verde e azul (RGB) e do infravermelho próximo (NIR) (Rasmussen *et al.*, 2016; Li *et al.*, 2021).

Isso é possível porque a interação da radiação eletromagnética (REM) com uma superfície provoca uma reflexão específica, conhecida por assinatura espectral, que caracteriza aquele tipo de material, e permite a identificação e distinção de diferentes materiais. A clorofila, por exemplo, absorve grande parte da luz nas faixas do vermelho e azul, enquanto reflete no verde, resultando na cor comum das plantas saudáveis. Já na banda do infravermelho (invisível ao olho humano), as células das folhas refletem intensamente a luz (Steffen, 2016).

Assim, os valores de índices de vegetação podem ser calculados para cada pixel da imagem, possibilitando a avaliação precisa de diversas características da vegetação que se tenha interesse com uso das imagens, com uso da relação das bandas espectrais realizadas por essas fórmulas (Venancio *et al.*, 2020).

Um índice de vegetação muito conhecido é o NDVI (*Normalized Difference Vegetation Index*) (Rouse *et al.*, 1973), que usa as bandas do vermelho e do

infravermelho próximo (NIR) para avaliar a saúde e vigor da vegetação, sendo utilizado em imagens para fins como delinear zonas de manejo de irrigação (Sapkota *et al.*, 2025), investigar padrões climatológicos e dinâmicas de vegetação (D'ercole *et al.*, 2024) e prever a produtividade de culturas (Panek; Gozdowski, 2020). Como a banda do infravermelho (NIR) não é visível ao olho humano, essa é uma vantagem que permite a detecção de estresses precocemente nas culturas, antes mesmo que a planta apresente algum sintoma visível (Sapkota *et al.*, 2023). Entretanto, por exigir o uso da banda do infravermelho, necessita que a imagem seja adquirida com uma câmera multiespectral, o que encarece consideravelmente o processo.

Entre os índices de vegetação que usam somente as bandas visíveis ao olho humano (RGB), podendo ser calculados a partir de imagens de câmeras comuns, se destaca o índice VARI (*Visible Atmospherically Resistant Index*) desenvolvido por Gitelson *et al.*, 2002. O VARI busca minimizar os efeitos atmosféricos e a reflectância do solo e tem sido usado, entre muitos fins, para avaliar a biomassa de plantas (Da *et al.*, 2025), para extrair informações do dossel de plantas para estimativa de produtividade (Zhou *et al.*, 2025; Wu *et al.*, 2025), para avaliar a saúde de plantas (Priyanka; Srivastava; Rawat, 2023) e detectar árvores suscetíveis a infestações de pragas (Trubin *et al.*, 2024). O fato de poderem ser calculados a partir de imagens comuns RGB torna os índices que trabalham com essas bandas muito mais acessíveis e econômicos de serem usados.

3.5.2. Segmentação, extração de características e classificação

Para que seja possível realizar análises de imagens de plantas na agricultura, é fundamental que se consiga separar os objetos de interesse, chamados de *foreground*, das demais coisas que aparecem na imagem (*background*), isto é, realizar a segmentação da imagem. Esse processo permite destacar as plantas em primeiro plano e fazer avaliações mais precisas das culturas (Hasan *et al.*, 2021).

A segmentação pode ser realizada com o uso de diversos métodos, como técnicas baseadas em limiares (*threshold*), em índices de cores (como os índices de vegetação) e em aprendizado (*learning-based*). Esses métodos utilizam diferentes características das imagens, como cor, textura e forma, para diferenciar os elementos desejados do fundo (*background*). O uso de algoritmos de processamento de imagem permite a automação desse processo, tornando-o mais eficiente e menos suscetível a erros humanos (Wang; Zhang; Wei, 2019; Cheng *et al.*, 2001)

Um dos algoritmos amplamente utilizados na segmentação de imagens é o algoritmo de Otsu, que busca determinar um limiar ótimo para separar os pixels da imagem em classes distintas. Este método baseia-se na análise estatística do histograma da imagem, buscando maximizar a variância interclasse e minimizar a variância intraclasse. Assim, o método de Otsu busca identificar um ponto ótimo (limiar) para a separação dos pixels entre objetos de interesse e fundo (Juwono *et al.*, 2023; Otsu, 1979).

É muito comum que o algoritmo de Otsu seja aplicado associado à técnica de segmentação baseada em índices de vegetação, para garantir a extração das características de interesse e a melhoria da performance do processo (Hamuda; Glavin; Jones, 2016).

Após a extração das características, é realizada a etapa de classificação. Um dos algoritmos mais utilizados para a classificação de imagens de dados agrícolas é o *Random Forest* (RF), que é um algoritmo de aprendizado de máquina que combina múltiplas árvores de decisão independentes para realizar previsões (Belgiu e Drăgu, 2016). O RF tem sido utilizado na agricultura para diversos fins, como para otimização da irrigação (Preite; Vignali, 2024), para predição de produtividade de culturas (Jhajharia; Mathur, 2023) e para diferenciação entre plantas daninhas e plantas de interesse (Gao *et al.*, 2018), sendo conhecido por ser capaz de analisar grandes volumes de dados com múltiplas colinearidades com boa precisão (Belgiu e Drăgu, 2016). O RF é flexível, tolera bem outliers e ruído, além de ser robusto contra o *overfitting*, um problema recorrente em muitos algoritmos de inteligência artificial (Setargie *et al.*, 2023; Aria; Cuccurullo; Gnasso, 2021; Zaimis; Gounaridis; Symenonakis, 2019). Esse problema ocorre quando um algoritmo se concentra em aspectos sem importância nos dados de treinamento, o que compromete sua capacidade de generalizar e lidar com novos dados, resultando em uma queda de desempenho quando aplicado a novos conjuntos de dados (Bramer, 2013).

REFERÊNCIAS

ALAM – ASSOCIACIÓN LATINOAMERICANA DE MALEZAS. Recomendaciones sobre unificación de los sistemas de evaluación en ensayos de control de malezas. **ALAM**, Bogotá, v. 1, p. 35-38, 1974.

ALBRECHT, L. P. *et al.* Métodos de controle de plantas daninhas. In: MARTINS, A. A.; MURATA, A. T. (Orgs.). **Matologia: estudos sobre plantas daninhas**. 1. ed. Jaboticabal: Fábrica da Palavra, 2021. Cap. 5, p. 145-169. Disponível em: https://www.matologia.com/_files/ugd/1a54d2_6bdc1f90aa6b47f6bb787706b381084e.pdf#page=145. Acesso em: 25 nov. 2024.

ALDEHOFF, A. S. *et al.* Revealing novel protein interaction partners of glyphosate in *Escherichia coli*. **Environment International**, v. 195, n. 109243, 2025. DOI: <https://doi.org/10.1016/j.envint.2024.109243>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0160412024008304?via%3Dihub>. Acesso em: 20 dez. 2024.

AMARASINGAM, N. *et al.* Bitou bush detection and mapping using UAV-based multispectral and hyperspectral imagery and artificial intelligence. **Remote Sensing Applications: Society and Environment**, v. 34, n. 101151, 2024. DOI: <https://doi.org/10.1016/j.rsase.2024.101151>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352938524000156?via%3Dihub>. Acesso em: 15 out. 2024.

AMPATZIDIS, Y.; PARTEL, V.; COSTA, L. Agroviz: Cloud-based application to process, analyze and visualize UAV-collected data for precision agriculture applications utilizing artificial intelligence. **Computers and Electronics in Agriculture**, v. 174, n. 105457, 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105457>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169920304695?via%3Dihub>. Acesso em: 15 out. 2024.

ANELLO, M. *et al.* Convolutional neural networks to assess bergamot essential oil content in the field from smartphone images. **Industrial Crops and Products**, v. 220, n. 119233, 2024. DOI: <https://doi.org/10.1016/j.indcrop.2024.119233>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S092666902401210X?via%3Dihub>. Acesso em: 24 jan. 2025.

ANUCH TIRANTI, J. V.; CURTI, R. N.; ACRECHE, M. M. Competitiveness of chia against brassica weeds improves through a narrow spatial arrangement. **Crop Protection**, v. 187, n. 106973 2025. DOI: <https://doi.org/10.1016/j.cropro.2024.106973>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0261219424004010?via%3Dihub>. Acesso em: 14 jan. 2025.

ARIA, M.; CUCCURULLO, C.; GNASSO, A. A comparison among interpretative proposals for Random Forests. **Machine Learning with Applications**, v. 6, n. 100094, 2021. DOI: <https://doi.org/10.1016/j.mlwa.2021.100094>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2666827021000475?via%3Dihub>. Acesso em: 15 out. 2024.

BELGIU, M.; DRĂGUȚ, L. Random Forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24-31, 2016. DOI: <https://doi.org/10.1016/j.isprsjprs.2016.01.011>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271616000265?via%3Dihub>. Acesso em: 15 out. 2024.

BEMELMANS, N. *et al.* Glyphosate application may influence the transfer of trace elements from soils to both soil solutions and plants. **Chemosphere**, v. 367, n. 143603, 2024. DOI: <https://doi.org/10.1016/j.chemosphere.2024.143603>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0045653524025037?via%3Dihub>. Acesso em: 20 dez. 2024.

BENBROOK, C. M. Trends in glyphosate herbicide use in the United States and globally. **Environmental Sciences Europe**, v. 28, n. 1, p. 3, 2016. DOI: <https://doi.org/10.1186/s12302-016-0070-0>. Disponível em: <https://enveurope.springeropen.com/articles/10.1186/s12302-016-0070-0>. Acesso em: 15 out. 2024.

BÍBLIA SAGRADA. Traduzida por João Ferreira de Almeida. Revista e atualizada no Brasil, 3. ed. (Nova Almeida Atualizada). Barueri, SP: **Sociedade Bíblica do Brasil**, 2017. ISBN 789-99-3840-47-20.

BRAMER, M. Avoiding overfitting of decision trees. In: BRAMER, M. Principles of data mining. **Undergraduate topics in computer science**. London: Springer, p. 121-136, 2013. DOI: https://doi.org/10.1007/978-1-4471-4884-5_9. Disponível em: https://link.springer.com/chapter/10.1007/978-1-4471-4884-5_9. Acesso em: 15 out. 2024.

BUSSE, M. *et al.* **Innovation mechanisms in German precision farming**. Precision Agriculture, v. 15, p. 403-426, 2014. DOI: <https://doi.org/10.1007/s11119-013-9337-2>. Disponível em: <https://link.springer.com/article/10.1007/s11119-013-9337-2>. Acesso em: 15 out. 2024.

CAMPOS, M. L. *et al.* Weed interference periods in cowpea crop. **Revista Caatinga**, v. 36, n. 1, p. 01-08, 2023. DOI: <https://doi.org/10.1590/1983-21252023v36n101rc>. Disponível em: <https://www.scielo.br/j/rcaat/a/dG9mQCCpBTRbcZ9ZVNqTx9j/?lang=en>. Acesso em: 28 nov. 2024.

CARAS, T. *et al.* Monitoring the effects of weed management strategies on tree canopy structure and growth using UAV-LiDAR in a young almond orchard. **Computers and Electronics in Agriculture**, v. 216, n. 108467, 2024. DOI: <https://doi.org/10.1016/j.compag.2023.108467>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169923008554?via%3Dihub>. Acesso em: 15 out. 2024.

CARDINALI, V. C. B. *et al.* Análise da expressão gênica da enzima EPSPS em *Conyza bonariensis* resistente ao glyphosate. In: **XXVII Congresso Brasileiro da Ciência das Plantas Daninhas**. p. 464-468 2010. Disponível em: <https://sbcpcd.org/uploads/trabalhos/analise-da-expressao-genica-da-enzima-epsps-em-conyza-bonariensis-resistente-ao-glyphosate-795.pdf>. Acesso em: 15 out. 2024.

CARNEIRO, R. P. *et al.* Variation of glyphosate spray volume in the drying of ground cover plants with an unmanned aerial vehicle. **Crop Protection**, v. 181, n. 106694, 2024. <https://doi.org/10.1016/j.cropro.2024.106694>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0261219424001224?via%3Dihub>. Acesso em: 14 jan. 2025.

CHAKHVASHVILI, E. *et al.* Multispectral imaging and terrestrial laser scanning for the detection of drought-induced paraheliotropic leaf movement in soybean. **International Journal of Applied Earth Observation and Geoinformation**, v. 135, n. 104250, 2024. DOI: <https://doi.org/10.1016/j.jag.2024.104250>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S156984322400606X?via%3Dihub>. Acesso em: 14 jan. 2025.

CHAUHAN, B. S. Grand challenges in weed management. **Frontiers in Agronomy**, v. 1, 2020. DOI: <https://doi.org/10.3389/fagro.2019.00003>. Disponível em: <https://www.frontiersin.org/journals/agronomy/articles/10.3389/fagro.2019.00003/full>. Acesso em: 6 jan. 2025.

CHENG, F.; CHENG, Z. Research progress on the use of plant allelopathy in agriculture and the physiological and ecological mechanisms of allelopathy. **Frontiers in Plant Science**, v. 6, n. 1020, 2015. DOI: <https://doi.org/10.3389/fpls.2015.01020>. Disponível em: <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2015.01020/full>. Acesso em: 16 nov. 2024.

CHENG, H. D. *et al.* Color image segmentation: advances and prospects. **Pattern Recognition**, v. 34, n. 12, p. 2259-2281, 2001. DOI: [https://doi.org/10.1016/S0031-3203\(00\)00149-7](https://doi.org/10.1016/S0031-3203(00)00149-7). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0031320300001497>. Acesso em: 15 out. 2024.

CHICONI, L. A. *et al.* Selectivity of herbicides isolated and/or with the addition of adjuvants for *Physalis angulata* crop. **Horticultura Brasileira**, v. 40, n. 2, p. 136-142, 2022. DOI: <https://doi.org/10.1590/s0102-0536-20220202>. Disponível em: <https://www.scielo.br/j/hb/a/sv8QnGtpPJw9jxq8QXyJhLm/?lang=en>. Acesso em: 14 jan. 2025.

CHRISTOFFOLETI, P. J.; LÓPEZ-OVEJERO, R. Principais aspectos da resistência de plantas daninhas ao herbicida glyphosate. **Planta daninha**, v. 21, p. 507-515, 2003. DOI: <https://doi.org/10.1590/S0100-83582003000300020>. Disponível em: <https://www.scielo.br/j/pd/a/gwwV6Mp4W6nVzmRkvCFvLdh/?lang=pt>. Acesso em: 15 out. 2024.

CODOGNOTTO, L. C. *et al.* Glifosato na produção e qualidade de forragem de capim marandu. Semina: **Ciências Agrárias**, v. 42, n. 3, suplemento 1, p. 1695-1706, 2021. DOI: <https://doi.org/10.5433/1679-0359.2021v42n3Supl1p1695>. Disponível em: <https://ojs.uel.br/revistas/uel/index.php/semagrarias/article/view/39882>. Acesso em: 20 dez. 2024.

COSTA, G. A. *et al.* Efficiency of glyphosate and carfentrazone-ethyl in the control of *Macroptilium atropurpureum* (DC.) Urb. under different light intensities. **South African Journal of Botany**, v. 131, p. 302-309, 2020. DOI:

<https://doi.org/10.1016/j.sajb.2020.02.028>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S0254629919302650?via%3Dihub>.
 Acesso em: 14 jan. 2025.

CUI, J. *et al.* Weed identification in soybean seedling stage based on UAV images and Faster R-CNN. **Computers and Electronics in Agriculture**, v. 227, Part 1, n. 109533, 2024. DOI: <https://doi.org/10.1016/j.compag.2024.109533>. Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S0168169924009244?via%3Dihub>
 . Acesso em: 14 jan. 2025.

DA, H. *et al.* Advancing soybean biomass estimation through multi-source UAV data fusion and machine learning algorithms. **Smart Agricultural Technology**, v. 10, n. 100778, 2025. DOI: <https://doi.org/10.1016/j.atech.2025.100778>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S2772375525000127?via%3Dihub>.
 Acesso em: 16 jan. 2025.

DANG, F. *et al.* YOLOWeeds: A novel benchmark of YOLO object detectors for multi-class weed detection in cotton production systems. **Computers and Electronics in Agriculture**, v. 205, n. 107655, 2023. DOI:
<https://doi.org/10.1016/j.compag.2023.107655>. Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S0168169923000431?via%3Dihub>
 . Acesso em: 24 jan. 2025.

DAS, T. K. *et al.* Herbicides use in crop production: An analysis of cost-benefit, non-target toxicities and environmental risks. **Crop Protection**, v. 181, n. 106691, 2024. DOI:
<https://doi.org/10.1016/j.cropro.2024.106691>. Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S0261219424001194?via%3Dihub>
 . Acesso em: 15 out. 2024.

D'ERCOLE, R. *et al.* A high temporal resolution NDVI time series to monitor drought events in the Horn of Africa. **International Journal of Applied Earth Observation and Geoinformation**, v. 135, n. 104264, 2024. DOI:
<https://doi.org/10.1016/j.jag.2024.104264>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S1569843224006204?via%3Dihub>.
 Acesso em: 25 jan. 2025.

EWRC – EUROPEAN WEED RESEARCH COUNCIL. Report of the 3rd and 4rd meetings of EWRC. Committee of methods in weed research. **Weed Res.**, v. 4, n. 1, p.88, 1964.

FERNANDES, T. *et al.* Levantamento fitossociológico de plantas daninhas em cultivos de abacaxi em diferentes épocas. **Revista Brasileira de Agropecuária Sustentável**, v. 11, n. 1, p. 322-335, 2021. DOI: <https://doi.org/10.21206/rbas.v11i1.12723>. Disponível em:
<https://periodicos.ufv.br/rbas/article/view/12723>. Acesso em: 28 nov. 2024.

FRANS, R. W. Measuring plants response. In: WILKINSON, R. E. (Ed.). **Research methods in weed science**. Puerto Rico: Weed Science Society, 1972. p.28-41.

GADE, S. A. *et al.* Advancements in UAV remote sensing for agricultural yield estimation: A systematic comprehensive review of platforms, sensors, and data analytics. **Remote Sensing Applications: Society and Environment**, v. 37, n. 101418, 2025. DOI:
<https://doi.org/10.1016/j.rsase.2024.101418>. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S2352938524002829?via%3Dihub>
. Acesso em: 14 jan. 2025.

GALON, L. *et al.* Chemical management of weeds in wheat culture. **Brazilian Journal of Science**, v. 2, n. 8, p. 1-22, 2023. DOI: <https://doi.org/10.14295/bjs.v2i8.344>. Disponível em: <https://periodicos.cerradopub.com.br/bjs/article/view/344>. Acesso em: 22 nov. 2024.

GAO, J. *et al.* Recognising weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery. **Biosystems Engineering**, v. 170, p. 39-50, 2018. DOI: <https://doi.org/10.1016/j.biosystemseng.2018.03.006>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S153751101730778X?via%3Dihub>
. Acesso em: 20 jan. 2025.

GHARDE, Y. *et al.* Assessment of yield and economic losses in agriculture due to weeds in India. **Crop Protection**, v. 107, p. 12-18, 2018. DOI: <https://doi.org/10.1016/j.cropro.2018.01.007>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0261219418300073?via%3Dihub>
. Acesso em: 14 jan. 2025.

GHIMIRE, B. K. *et al.* Evaluation of pre-emergence and post-emergence herbicides for weed management in *Miscanthus sacchariflorus* and *Miscanthus sinensis*. **Phyton-International Journal of Experimental Botany**, v. 92, n. 5, p. 1439-1467, 2023. DOI: <https://doi.org/10.32604/phyton.2023.023076>. Disponível em: <https://www.techscience.com/phyton/v92n5/51859>. Acesso em: 20 dez. 2024.

GITELSON, A. A. *et al.* Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76-87, 2002. DOI: [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425701002899?via%3Dihub>
. Acesso em: 20 jan. 2025.

GOMES, G. L. G. C. *et al.* Cadastramento fitossociológico de plantas daninhas na bananicultura. **Planta daninha**, v. 28, p. 61-68, 2010. DOI: <https://doi.org/10.1590/S0100-83582010000100008>. Disponível em: <https://www.scielo.br/j/pd/a/sPT8yD57QGqPH4tNpKVXnnt/?lang=pt>. Acesso em: 25 set. 2024.

GRILLO, R. *et al.* Chitosan/tripolyphosphate nanoparticles loaded with paraquat herbicide: An environmentally safer alternative for weed control. **Journal of Hazardous Materials**, v. 278, p. 163-171, 2014. DOI: <https://doi.org/10.1016/j.jhazmat.2014.05.079>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0304389414004245?via%3Dihub>
. Acesso em: 20 dez. 2024.

HAMUDA, E.; GLAVIN, M.; JONES, E. A survey of image processing techniques for plant extraction and segmentation in the field. **Computers and Electronics in Agriculture**, v. 125, p. 184-199, 2016. DOI: <https://doi.org/10.1016/j.compag.2016.04.024>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169916301557?via%3Dihub>
. Acesso em: 15 out. 2024.

HASAN, A. S. M. M. *et al.* A survey of deep learning techniques for weed detection from images. **Computers and Electronics in Agriculture**, v. 184, n. 106067, 2021. DOI: <https://doi.org/10.1016/j.compag.2021.106067>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169921000855?via%3Dihub>. Acesso em: 15 out. 2024.

IBAMA - INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS. Assuntos. Químicos e biológicos. Agrotóxicos. **Painéis de informações de agrotóxicos**. 2025. Portal Gov.br. Disponível em: <https://www.gov.br/ibama/pt-br/assuntos/quimicos-e-biologicos/agrotoxicos/paineis-de-informacoes-de-agrotoxicos/paineis-de-informacoes-de-agrotoxicos#Painel-comercializacao>. Acesso em: 14 jan. 2025.

IHEATURU, C. J. *et al.* Integrating UAV LiDAR and multispectral data to assess forest status and map disturbance severity in a West African forest patch. **Ecological Informatics**, v. 84, n. 102876, 2024. DOI: <https://doi.org/10.1016/j.ecoinf.2024.102876>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1574954124004187?via%3Dihub>. Acesso em: 14 jan. 2025.

JENSEN, H. G. *et al.* Socioeconomic impact of widespread adoption of precision farming and controlled traffic systems in Denmark. **Precision Agriculture**, v. 13, p. 661-677, 2012. DOI: <https://doi.org/10.1007/s11119-012-9276-3>. Disponível em: <https://link.springer.com/article/10.1007/s11119-012-9276-3>. Acesso em: 15 out. 2024.

JHAJHARIA, K.; MATHUR, P. Prediction of crop yield using satellite vegetation indices combined with machine learning approaches. **Advances in Space Research**, v. 72, n. 9, p. 3998-4007, 2023. DOI: <https://doi.org/10.1016/j.asr.2023.07.006>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0273117723005264?via%3Dihub>. Acesso em: 20 jan. 2025.

JIN, Z. *et al.* Research on the rice fertiliser decision-making method based on UAV remote sensing data assimilation. **Computers and Electronics in Agriculture**, v. 216, n. 108508, 2024. DOI: <https://doi.org/10.1016/j.compag.2023.108508>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169923008967?via%3Dihub>. Acesso em: 15 jan. 2025.

JUWONO, F. H. *et al.* Machine learning for weed–plant discrimination in agriculture 5.0: An in-depth review. **Artificial Intelligence in Agriculture**, v. 10, p. 13-25, 2023. DOI: <https://doi.org/10.1016/j.aiaa.2023.09.002>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2589721723000363?via%3Dihub>. Acesso em: 15 out. 2024.

LI, L.; DENICH, M. Niche and interspecific relationship of alligator weed (*Alternanthera philoxeroides*) after a hundred years' invasion in central China. **Heliyon**, v. 10, n. 20, 2024. DOI: <https://doi.org/10.1016/j.heliyon.2024.e39064>. Disponível em: [https://www.cell.com/heliyon/fulltext/S2405-8440\(24\)15095-5?_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844024150955%3Fshowall%3Dtrue](https://www.cell.com/heliyon/fulltext/S2405-8440(24)15095-5?_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844024150955%3Fshowall%3Dtrue). Acesso em: 14 jan. 2025.

LI, S. *et al.* High-quality vegetation index product generation: A review of NDVI time series reconstruction techniques. **International Journal of Applied Earth Observation and Geoinformation**, v. 105, n. 102640, 2021. DOI: <https://doi.org/10.1016/j.jag.2021.102640>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0303243421003470>. Acesso em: 15 out. 2024.

LIN, Y.-C.; HABIB, A. Quality control and crop characterization framework for multi-temporal UAV LiDAR data over mechanized agricultural fields. **Remote Sensing of Environment**, v. 256, n. 112299, 2021. DOI: <https://doi.org/10.1016/j.rse.2021.112299>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425721000171?via%3Dihub>. Acesso em: 14 jan. 2025.

LÓPEZ-CHÁVEZ, M. Y. *et al.* Continuous glyphosate applications affect plant development of mangrove species from coastal wetlands: *Rhizophora mangle* and *Pachira aquatica*. **Aquatic Botany**, v. 187, n. 103658, 2023. DOI: <https://doi.org/10.1016/j.aquabot.2023.103658>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0304377023000438?via%3Dihub>. Acesso em: 20 dez. 2024.

LUKANGILA, M. A. *et al.* Evaluating the effects of manual hoeing and selective herbicides on maize (*Zea mays* L.) productivity and profitability. **Heliyon**, v. 10, n. 13, 2024. DOI: <https://doi.org/10.1016/j.heliyon.2024.e33294>. Disponível em: [https://www.cell.com/heliyon/fulltext/S2405-8440\(24\)09325-3?_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844024093253%3Fshow](https://www.cell.com/heliyon/fulltext/S2405-8440(24)09325-3?_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844024093253%3Fshow). Acesso em: 20 dez. 2024.

MACÍAS, F. A.; MEJÍAS, F. J.; MOLINILLO, J. M. Recent advances in allelopathy for weed control: from knowledge to applications. **Pest management science**, v. 75, p. 2413-2436, 2019. DOI: <https://doi.org/10.1002/ps.5355>. Disponível em: <https://scijournals.onlinelibrary.wiley.com/doi/10.1002/ps.5355>. Acesso em: 14 jan. 2025.

MARCONI, A. *et al.* Garlic yield monitoring using vegetation indices and texture features derived from UAV multispectral imagery. **Smart Agricultural Technology**, v. 8, n. 100513, 2024. DOI: <https://doi.org/10.1016/j.atech.2024.100513>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2772375524001187?via%3Dihub>. Acesso em: 15 jan. 2025.

MARKUS, C. *et al.* Resistência de plantas daninhas aos herbicidas. In: MARTINS, A. A.; MURATA, A. T. (Orgs.). **Matologia: estudos sobre plantas daninhas**. 1. ed. Jaboticabal: Fábrica da Palavra, 2021. Cap. 10, p. 324-364. Disponível em: https://www.matologia.com/_files/ugd/1a54d2_6bdc1f90aa6b47f6bb787706b381084e.pdf#page=324. Acesso em: 25 nov. 2024.

MKHIZE, Y. *et al.* Mapping weed infestation in maize fields using Sentinel-2 data. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 134, n. 103571, 2024. DOI: <https://doi.org/10.1016/j.pce.2024.103571>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1474706524000299?via%3Dihub>. Acesso em: 15 jan. 2025.

MOAZZAM, S. I. *et al.* Towards automated weed detection through two-stage semantic segmentation of tobacco and weed pixels in aerial imagery. **Smart Agricultural Technology**, v. 4, n. 100142, 2023. DOI: <https://doi.org/10.1016/j.atech.2022.100142>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S277237552200106X?via%3Dihub>. Acesso em: 15 jan. 2025.

NASCIMENTO, P. *et al.* Screening of plant extracts for a microcosm in vivo test of inhibition of the toxic bloom-forming cyanobacteria *Chrysochloris ovalisporum*. **Algal Research**, v. 80, n. 103552, 2024. DOI: <https://doi.org/10.1016/j.algal.2024.103552>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2211926424001644?via%3Dihub>. Acesso em: 20 dez. 2024.

NAZEER, I. *et al.* Artificial intelligence-based smart agricultural systems for saffron cultivation with integration of Unmanned Aerial Vehicle imagery and deep learning approaches. **Computers and Electrical Engineering**, v. 119, n. 109542, 2024. DOI: <https://doi.org/10.1016/j.compeleceng.2024.109542>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0045790624004695?via%3Dihub>. Acesso em: 15 out. 2024.

NOVOTNY, E. Glyphosate, Roundup and the Failures of Regulatory Assessment. **Toxics**, v. 10, n. 6, p. 321, 2022. DOI: <https://doi.org/10.3390/toxics10060321>. Disponível em: <https://www.mdpi.com/2305-6304/10/6/321>. Acesso em: 14 jan. 2025.

NUNES, R. F. F. *et al.* Glyphosate contamination of drinking water and the occurrence of oxidative stress: Exposure assessment to rural Brazilian populations. **Environmental Toxicology and Pharmacology**, v. 108, n. 104476, 2024. DOI: <https://doi.org/10.1016/j.etap.2024.104476>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1382668924001169?via%3Dihub>. Acesso em: 20 dez. 2024.

OERKE, E.-C. Crop losses to pests. **The Journal of Agricultural Science**, v. 144, n. 1, p. 31-43, 2006. DOI: <https://doi.org/10.1017/S0021859605005708>. Disponível em: <https://www.cambridge.org/core/journals/journal-of-agricultural-science/article/abs/crop-losses-to-pests/AD61661AD6D503577B3E73F2787FE7B2>. Acesso em: 6 jan. 2025.

OKUMU, M. N.; VORSTER, B. J.; REINHARDT, C. F. Growth-stage and temperature influence glyphosate resistance in *Conyza bonariensis* (L.) Cronquist. **South African Journal of Botany**, v. 121, p. 248-256, 2019. DOI: <https://doi.org/10.1016/j.sajb.2018.10.034>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0254629918306847?via%3Dihub>. Acesso em: 25 nov. 2024.

OLIVEIRA JÚNIOR, R. S. *et al.* Mecanismos de ação de herbicidas. In: MARTINS, A. A.; MURATA, A. T. (Orgs.). **Matologia: estudos sobre plantas daninhas**. 1. ed. Jaboticabal: Fábrica da Palavra, 2021. Cap. 6, p. 170-204.

OLIVEIRA, V. V. *et al.* The light intensity in the cultivation environment and the impact of glyphosate on plants of the *Urochloa* genus. **Journal of Environmental Science and Health, Part B**, v. 59, n. 8, p. 540-549, 2024. DOI:

<https://doi.org/10.1080/03601234.2024.2381934>. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/03601234.2024.2381934>. Acesso em: 14 jan. 2025.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62-66, 1979.

PANEK, E.; GOZDOWSKI, D. Analysis of relationship between cereal yield and NDVI for selected regions of Central Europe based on MODIS satellite data. **Remote Sensing Applications: Society and Environment**, v. 17, n. 100286, 2020. DOI: <https://doi.org/10.1016/j.rsase.2019.100286>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352938519303027?via%3Dihub>. Acesso em: 25 jan. 2025.

PEDERSEN, S. M. *et al.* Adoption and perspectives of precision farming in Denmark. **Acta Agriculturae Scandinavica, Section B — Soil & Plant Science**, v. 54, n. 1, p. 2-8, 2004. DOI: <https://doi.org/10.1080/09064710310019757>. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/09064710310019757>. Acesso em: 15 out. 2024.

PORRU, S. *et al.* Short occupational exposure to glyphosate and its biomonitoring via urinary levels of glyphosate and metabolite AMPA (Amino-MethylPhosphonic acid), in Italian vineyard workers. **Heliyon**, v. 10, n. 16, 2024. DOI: <https://doi.org/10.1016/j.heliyon.2024.e36407>. Disponível em: [https://www.cell.com/heliyon/fulltext/S2405-8440\(24\)12438-3?_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844024124383%3Fshowall%3Dtrue](https://www.cell.com/heliyon/fulltext/S2405-8440(24)12438-3?_returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS2405844024124383%3Fshowall%3Dtrue). Acesso em: 20 dez. 2024.

PRANASWI, D. *et al.* Analyzing the synergistic impact of UAV-based technology and knapsack sprayer on weed management, yield-contributing traits, and yield in wheat (*Triticum aestivum* L.) for enhanced agricultural operations. **Computers and Electronics in Agriculture**, v. 219, n. 108796, 2024. DOI: <https://doi.org/10.1016/j.compag.2024.108796>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016816992400187X?via%3Dihub>. Acesso em: 14 jan. 2025.

PREITE, L.; VIGNALI, G. Artificial intelligence to optimize water consumption in agriculture: A predictive algorithm-based irrigation management system. **Computers and Electronics in Agriculture**, v. 223, n. 109126, 2024. DOI: <https://doi.org/10.1016/j.compag.2024.109126>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169924005179?via%3Dihub>. Acesso em: 20 jan. 2025.

PRIYANKA; SRIVASTAVA, P. K.; RAWAT, R. Retrieval of leaf chlorophyll content using drone imagery and fusion with Sentinel-2 data. **Smart Agricultural Technology**, v. 6, n. 100353, 2023. DOI: <https://doi.org/10.1016/j.atech.2023.100353>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S277237552300182X?via%3Dihub>. Acesso em: 16 jan. 2025.

RAM, B. G. *et al.* A systematic review of hyperspectral imaging in precision agriculture: Analysis of its current state and future prospects. **Computers and Electronics in**

Agriculture, v. 222, n. 109037, 2024. DOI: <https://doi.org/10.1016/j.compag.2024.109037>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169924004289?via%3Dihub>. Acesso em: 15 jan. 2025.

RASMUSSEN, J. *et al.* Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots? **European Journal of Agronomy**, v. 74, p. 75-92, 2016. DOI: <https://doi.org/10.1016/j.eja.2015.11.026>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1161030115300733>. Acesso em: 15 out. 2024.

REGINALDO, L. T. R. T. *et al.* Weed interference in carrot yield in two localized irrigation systems. **Revista Caatinga**, v. 34, n. 1, p. 119-131, 2021. DOI: <https://doi.org/10.1590/1983-21252021v34n113rc>. Disponível em: <https://www.scielo.br/j/rcaat/a/HLvpD7SzsnsQsGyGMY4ww6cH/?lang=en>. Acesso em: 28 nov. 2024.

REVENGA, J. C. *et al.* Independent estimates of net carbon uptake in croplands: UAV-LiDAR and machine learning vs. eddy covariance. **Agricultural and Forest Meteorology**, v. 355, n. 110106, 2024. DOI: <https://doi.org/10.1016/j.agrformet.2024.110106>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168192324002211?via%3Dihub>. Acesso em: 14 jan. 2025.

ROUSE, J. W. *et al.* Monitoring vegetation systems in the great plains with ERTS. In: Third ERTS Symposium, **Proceedings**. NASA SP-351, NASA, Washington, DC, v. 1, p. 309-317, 1973.

RUIZ, G. A. P. *et al.* Selectivity of pre-emergent herbicides in cassava (*Manihot esculenta* Crantz) and its relationship with the stem cutting planting system. **Crop Protection**, v. 187, n. 106985, 2025. DOI: <https://doi.org/10.1016/j.cropro.2024.106985>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0261219424004137?via%3Dihub>. Acesso em: 14 jan. 2025.

SALAZAR-REQUE, I. *et al.* Differentiating nutritional and water statuses in Hass avocado plantations through a temporal analysis of vegetation indices computed from aerial RGB images. **Computers and Electronics in Agriculture**, v. 213, n. 108246, 2023. DOI: <https://doi.org/10.1016/j.compag.2023.108246>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169923006348?via%3Dihub>. Acesso em: 15 out. 2024.

SAPKOTA, A. *et al.* Comparative analysis of evapotranspiration (ET), crop water stress index (CWSI), and normalized difference vegetation index (NDVI) to delineate site-specific irrigation management zones in almond orchards. **Scientia Horticulturae**, v. 339, n. 113860, 2025. DOI: <https://doi.org/10.1016/j.scienta.2024.113860>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0304423824010124?via%3Dihub>. Acesso em: 25 jan. 2025.

SAPKOTA, A. *et al.* Response of Landscape Groundcovers to Deficit Irrigation: An Assessment Based on Normalized Difference Vegetation Index and Visual Quality Rating. **HortScience**, v. 58, n. 3, p. 274-285, 2023. DOI: <https://doi.org/10.21273/HORTSCI16915-22>. Disponível em: <https://journals.ashs.org/hortsci/view/journals/hortsci/58/3/article-p274.xml>. Acesso em: 26 jan. 2025.

SCHERER, M. B. *et al.* Herbicidas pré-emergentes para manejo de milho voluntário RR® na cultura da soja. **Revista Brasileira de Herbicidas**, v. 16, n. 1, p. 1-10. DOI: <https://doi.org/10.7824/rbh.v16i1.491>. Disponível em: <https://www.rbherbicidas.com.br/index.php/rbh/article/view/491>. Acesso em: 14 jan. 2025.

SETARGIE, T. A. *et al.* Random Forest–based gully erosion susceptibility assessment across different agro-ecologies of the Upper Blue Nile basin, Ethiopia. **Geomorphology**, v. 431, n. 108671, 2023. DOI:10.1016/j.geomorph.2023.108671. Disponível em: [eResearchgate.net/publication/369572849_Random_Forest-based_gully_erosion_susceptibility_assessment_across_different_agro-ecologies_of_the_Upper_Blue_Nile_basin_Ethiopia](https://www.researchgate.net/publication/369572849_Random_Forest-based_gully_erosion_susceptibility_assessment_across_different_agro-ecologies_of_the_Upper_Blue_Nile_basin_Ethiopia). Acesso em: 15 out. 2024.

SHAHARE, Y. R. *et al.* ASUR: Agriculture Soil Fertility Assessment Using Random Forest Classifier and Regressor. **Procedia Computer Science**, v. 235, p. 1732-1741, 2024. DOI: <https://doi.org/10.1016/j.procs.2024.04.164>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050924008408?via%3Dihub>. Acesso em: 20 jan. 2025.

SILVA, A. A. *et al.* Biologia de Plantas Daninhas. In: SILVA, A. A.; SILVA, J. F. (Orgs.). **Tópicos em manejo de plantas daninhas**. Viçosa: Editora UFV, 2007a. Cap. 1. p. 1-40.

SILVA, A. A. *et al.* Herbicidas: classificação e mecanismos de ação. In: SILVA, A. A.; SILVA, J. F. (Orgs.). **Tópicos em manejo de plantas daninhas**. Viçosa: Ed. UFV, 2007b. Cap. 3. p. 59-117.

SILVA, A. F. M. *et al.* Introdução à ciência das plantas daninhas. In: MARTINS, A. A.; MURATA, A. T. (Orgs.). **Matologia: estudos sobre plantas daninhas**. 1. ed. Jaboticabal: Fábrica da Palavra, 2021. Cap. 1, p. 7-37. Disponível em: https://www.matologia.com/_files/ugd/1a54d2_6bdc1f90aa6b47f6bb787706b381084e.pdf#page=7. Acesso em: 25 nov. 2024.

SOARES, C. *et al.* Is soil contamination by a glyphosate commercial formulation truly harmless to non-target plants? – Evaluation of oxidative damage and antioxidant responses in tomato. **Environmental Pollution**, v. 247, p. 256-265, 2019. DOI: <https://doi.org/10.1016/j.envpol.2019.01.063>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0269749118348838?via%3Dihub>. Acesso em: 20 dez. 2024.

SOCIEDADE BRASILEIRA DA CIÊNCIA DAS PLANTAS DANINHAS – SBPCPD. **Procedimentos para instalação, avaliação e análise de experimentos com herbicidas**. Londrina: SBPCPD, 1995. 42 p.

SOUSA, R. M.; SOUSA, R. O. Levantamento populacional de plantas daninhas na cultura da laranja no Município de Rorainópolis, Roraima, Brasil. **Ambiente: Gestão e Desenvolvimento**, v. 16, n. 3, p. 36-50, 2024. DOI: <https://doi.org/10.24979/nd2s2y34>. Disponível em: <https://periodicos.uerr.edu.br/index.php/ambiente/article/view/1029>. Acesso em: 28 nov. 2024.

SOW, S. *et al.* Artificial intelligence for maximizing agricultural input use efficiency: Exploring nutrient, water and weed management strategies. **Phyton-International Journal of Experimental Botany**, v. 93, n. 7, p. 1569-1598, 2024. DOI: <https://doi.org/10.32604/phyton.2024.052241>. Disponível em: <https://www.techscience.com/phyton/v93n7/57480>. Acesso em: 15 jan. 2025.

SPADOTTO, C. A.; GOMES, M. A. F. **Agrotóxicos no Brasil**. Embrapa, Agricultura e Meio Ambiente, 2021. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/agricultura-e-meio-ambiente/qualidade/dinamica/agrotoxicos-no-brasil#:~:text=Anualmente%20s%C3%A3o%20usados%20no%20mundo,mil%20toneladas%20de%20produtos%20comerciais>. Acesso em: 15 out. 2024.

STEFFEN, C. A. **Introdução ao Sensoriamento Remoto**. Instituto Nacional de Pesquisas Espaciais, Divisão de Sensoriamento Remoto, 2016. Disponível em: <http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>. Acesso em: 15 out. 2024.

STREHLOW, B.; DE MOL, F.; GEROWITT, B. Herbicide intensity depends on cropping system and weed control target: Unraveling the effects in field experiments. **Crop Protection**, v. 129, n. 105011, 2020. DOI: <https://doi.org/10.1016/j.cropro.2019.105011>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0261219419303576?via%3Dihub>. Acesso em: 15 jan. 2025.

SU, J. *et al.* Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery. **Computers and Electronics in Agriculture**, v. 192, n. 10662, 2022. DOI: <https://doi.org/10.1016/j.compag.2021.106621>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169921006384?via%3Dihub>. Acesso em: 14 jan. 2025.

TRUBIN, A. *et al.* Detection of green attack and bark beetle susceptibility in Norway Spruce: Utilizing PlanetScope Multispectral Imagery for Tri-Stage spectral separability analysis. **Forest Ecology and Management**, v. 560, n. 121838, 2024. DOI: <https://doi.org/10.1016/j.foreco.2024.121838>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0378112724001506?via%3Dihub>. Acesso em: 17 jan. 2025.

TUFFI SANTOS, L. D. *et al.* Leaf anatomy and morphometry in three eucalypt clones treated with glyphosate. **Brazilian Journal of Biology**, v. 69, p. 129-136, 2009. DOI: <https://doi.org/10.1590/S1519-69842009000100016>. Disponível em: <https://www.scielo.br/j/bjb/a/p6kQgj3pvzt6ncqYfLZhLMR/?lang=en>. Acesso em: 15 out. 2024.

VENANCIO, L. P. *et al.* Potential of using spectral vegetation indices for corn green biomass estimation based on their relationship with the photosynthetic vegetation sub-

pixel fraction. **Agricultural Water Management**, v. 236, n. 106155, 2020. DOI: <https://doi.org/10.1016/j.agwat.2020.106155>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378377419317585?via%3Dihub>. Acesso em: 15 out. 2024.

VENKATARAJU, A. *et al.* A review of machine learning techniques for identifying weeds in corn. **Smart Agricultural Technology**, v. 3, n. 100102, 2023. DOI: <https://doi.org/10.1016/j.atech.2022.100102>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2772375522000673?via%3Dihub>. Acesso em: 15 out. 2024.

WANG, A.; ZHANG, W.; WEI, X. A review on weed detection using ground-based machine vision and image processing techniques. **Computers and Electronics in Agriculture**, v. 158, p. 226-240, 2019. DOI: <https://doi.org/10.1016/j.compag.2019.02.005>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169918317150?via%3Dihub>. Acesso em: 15 out. 2024.

WIEDERHECKER, A. *et al.* Ten years of directing seeding restoration in the Brazilian savanna: Lessons learned and the way forward. **Journal of Environmental Management**, v. 365, n. 121576, 2024. DOI: <https://doi.org/10.1016/j.jenvman.2024.121576>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0301479724015627?via%3Dihub>. Acesso em: 20 dez. 2024.

WU, Y. *et al.* Accurate estimation of grain number per panicle in winter wheat by synergistic use of UAV imagery and meteorological data. **International Journal of Applied Earth Observation and Geoinformation**, v. 136, n. 104320, 2025. DOI: <https://doi.org/10.1016/j.jag.2024.104320>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1569843224006782?via%3Dihub>. Acesso em: 16 jan. 2025.

YU, R. *et al.* Early detection of pine wilt disease using deep learning algorithms and UAV-based multispectral imagery. **Forest Ecology and Management**, v. 497, n. 119493, 2021. DOI: <https://doi.org/10.1016/j.foreco.2021.119493>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S037811272100582X?via%3Dihub>. Acesso em: 14 jan. 2025.

ZAIMES, G. N.; GOUNARIDIS, D.; SYMENONAKIS, E. Assessing the impact of dams on riparian and deltaic vegetation using remotely-sensed vegetation indices and Random Forests modelling. **Ecological Indicators**, v. 103, p. 630-641, 2019. DOI: <https://doi.org/10.1016/j.ecolind.2019.04.047>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1470160X19302900?via%3Dihub>. Acesso em: 15 out. 2024.

ZENG, T. *et al.* Early detection of rubber tree powdery mildew using UAV-based hyperspectral imagery and deep learning. **Computers and Electronics in Agriculture**, v. 220, n. 108909, 2024. DOI: <https://doi.org/10.1016/j.compag.2024.108909>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169924003004?via%3Dihub>. Acesso em: 14 jan. 2025.

ZHOU, L. *et al.* Soybean yield estimation and lodging classification based on UAV multi-source data and self-supervised contrastive learning. **Computers and Electronics in Agriculture**, v. 230, n. 109822, 2025. DOI: <https://doi.org/10.1016/j.compag.2024.109822>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169924012134?via%3Dihub>. Acesso em: 16 jan. 2025.

4. ARTIGOS

4.1. Artigo 1 - Uso de imagens de *smartphone* na avaliação do controle de plantas daninhas por glyphosate: uma abordagem computacional por *Random Forest*

Artigo elaborado conforme normas da revista *Computers and Electronics in Agriculture*.

USO DE IMAGENS DE SMARTPHONE NA AVALIAÇÃO DO CONTROLE DE PLANTAS DANINHAS POR GLYPHOSATE: UMA ABORDAGEM COMPUTACIONAL POR RANDOM FOREST

RESUMO

A avaliação da eficácia de controle de herbicidas é fundamental no manejo integrado de plantas daninhas e suas informações retroalimentam a base de dados para futuras ações na proteção dos cultivos. A avaliação de controle de plantas daninhas por herbicidas é feita a partir de avaliações visuais *in loco*, podendo ser demorada e imprecisa. Neste estudo foram propostos modelos capazes de avaliar a eficácia do controle de *Urochloa brizantha* por glyphosate utilizando análise computacional de imagens por *Random Forest*. As imagens foram obtidas com *smartphone* em área com infestação de *U. brizantha* dessecada por glyphosate. Para estratificação da resposta de controle foram aplicadas as doses 0, 144, 288, 576, 864, 1152 e 1440 g e.a. ha⁻¹ de glyphosate. Para estimação dos modelos, usou-se 27 índices de vegetação como variáveis de entrada, buscando-se estimar o controle com base nos dados de avaliação visual e com base nos dados de porcentagem de controle determinado pela massa vegetal morta pela ação do herbicida. O modelo desenvolvido com os dados das notas visuais de controle apresentou ótimo desempenho, tanto no treinamento (r^2 de 0,92), como na validação (r^2 de 0,92). O modelo treinado com os dados de porcentagem de massa vegetal morta também apresentou desempenho satisfatório, com r^2 de 0,88 para a amostra de treinamento e de 0,90 para a amostra de validação. O método de avaliação proposto apresenta vantagens em relação aos métodos usuais, devido à facilidade de obtenção das imagens de *smartphone* e possibilidade de inserção dos índices e modelos desenvolvidos em aplicativos móveis.

Palavras-chave: *machine learning*, árvore de decisão, inteligência artificial, índices de vegetação.

USE OF SMARTPHONE IMAGES IN THE WEED CONTROL EVALUATION WITH GLYPHOSATE: A COMPUTATIONAL APPROACH USING RANDOM FOREST

ABSTRACT

The evaluation of herbicide control efficacy is fundamental in integrated weed management and its information feeds back into the database for future actions to protect crops. The evaluation of weed control by herbicides is carried out based on on-site visual evaluations, which can be time-consuming and imprecise. In this study, models capable of evaluating the efficacy of *Urochloa brizantha* control by glyphosate were proposed using computational image analysis with Random Forest. The images were obtained with a smartphone in an area with *U. brizantha* infestation desiccated by glyphosate. To stratify the control response, glyphosate doses of 0, 144, 288, 576, 864, 1152, and 1440 g a.e. ha⁻¹ were applied. For model estimation, 27 vegetation indices were used as input variables, with the objective of estimating control based on visual evaluation data and on control percentage data determined by the plant mass killed by the action of the herbicide. The model developed with data from visual control scores presented excellent performance, both in training (r^2 of 0.92) and in validation (r^2 of 0.92). The model trained with the percentage of dead plant mass also presented satisfactory performance, with an r^2 of 0.88 for the training sample and 0.90 for the validation sample. The proposed evaluation method presents advantages over the usual methods, due to the ease of obtaining smartphone images and the possibility of inserting the indices and models developed in mobile applications.

Keywords: machine learning, decision tree, artificial intelligence, vegetation indices.

Introdução

Grande parte da produção agrícola mundial é perdida devido a problemas com plantas daninhas, mesmo após a adoção de algum método de controle (Oerke, 2006; Gharde *et al.*, 2018; Chauhan, 2020). O método de controle mais usado contra essas plantas indesejadas é o controle químico com herbicidas, sendo o glyphosate o herbicida mais utilizado mundialmente (Benbrook, 2016; Novotny, 2022). No Brasil, o glyphosate representou 54% das vendas de herbicidas em 2022 (266,09 mil toneladas de produto formulado), volume quatro vezes maior que do segundo colocado, o herbicida 2,4 D (IBAMA, 2025). O glyphosate também é o principal herbicida usado na limpeza das áreas no plantio convencional e na dessecação da vegetação em sistemas conservacionistas como Zero-Tillage ou Non-Tillage no Brasil (Agrofit, 2024; Oliveira *et al.*, 2024), incluindo a dessecação de plantas do gênero *Urochloa*. As gramíneas do gênero *Urochloa* são amplamente utilizadas como forrageiras e plantas de cobertura do solo em plantio direto no Brasil, sendo importantes em toda região Neotropical, África Subsaariana e Sudeste Asiático (Fuglie *et al.*, 2021).

O uso racional de herbicidas tem ganhado cada vez mais importância no cenário mundial, em uma perspectiva agronômica, a dependência do uso de herbicidas leva a problemas como redução da diversidade de plantas em agroecossistemas, deriva dos herbicidas em áreas vizinhas e seleção de plantas resistentes (Strehlow *et al.*, 2020) e tolerantes aos herbicidas. Outro ponto é a preocupação ambiental em relação ao seu uso excessivo e/ou inadequado, capaz de gerar problemas como contaminação de corpos d'água, toxicidade para a microbiota do solo (dependendo do tipo de herbicida, dose aplicada, temperatura e tempo após a aplicação), resíduos no solo, água e cadeia alimentar e contaminação de humanos e animais (Das *et al.*, 2024).

A adoção do controle químico envolve as etapas de diagnóstico da área, escolha do herbicida apropriado, aplicação e avaliação da eficácia de controle. A avaliação da eficácia de controle é fundamental no programa de manejo integrado de plantas daninhas e suas informações retroalimentam a base de dados para futuros tratamentos e ações de manejo (Oliveira *et al.*, 2024). Atualmente, a avaliação de controle de plantas daninhas por herbicidas é feita a partir de avaliações visuais *in loco* por pessoa treinada, sendo atribuídas notas de controle em função da ação do produto sobre as plantas (Frans, 1972; SBCPD, 1995; Ghimire *et al.*, 2023). O controle também pode ser avaliado pela massa vegetal remanescente pós-tratamento herbicida, em que amostras da parte aérea

das plantas são coletadas e separadas em material vivo e material morto, possibilitando o cálculo da porcentagem de material morto pelo herbicida (Oliveira *et al.*, 2024).

A avaliação visual por escala de notas da eficiência de controle de plantas daninhas por herbicidas (Frans, 1972; SBCPD, 1995; Ghimire *et al.*, 2023) é dependente da experiência do avaliador, podendo se tornar demorada, ineficiente e imprecisa. A geração de modelos por aprendizado de máquina e sua implementação na criação de aplicativos pode tornar a avaliação mais rápida e confiável, considerando a subjetividade da avaliação humana.

Uma possível alternativa a esse método tradicional é o uso de imagens capturadas por *smartphone*, associado a índices de vegetação (IVs) e uso de inteligência artificial, sendo também uma solução mais acessível para captura de imagens ao uso de equipamentos de alto custo. O uso de análise computacional de imagens tem se difundido nas ciências agrárias, devido à sua potencialidade de automação e aumento da eficiência e precisão em diversos setores agrícolas (Sow *et al.*, 2024; Ram *et al.*, 2024).

O tratamento computacional de imagens tem sido usado para diversos fins nas ciências agrárias, como na detecção de plantas de interesse frente à presença de plantas daninhas (Moazzam *et al.*, 2023), para melhorar a precisão de aplicação de herbicidas (Asad e Bais, 2020), para avaliação do estado nutricional e hídrico de plantas (Salazar-Reque *et al.*, 2023), para identificação de injúrias de doenças em culturas (Nandhini *et al.*, 2022), para desenvolvimento de sistemas de aplicação de herbicida inteligentes (Upadhyay *et al.*, 2024) e até mesmo para o desenvolvimento de um robô autônomo para controle de plantas daninhas (Raja *et al.*, 2023).

Uma importante ferramenta de inteligência artificial e aprendizado de máquina que pode ser utilizada para avaliar o controle de plantas daninhas são as árvores de decisão, entre as quais se destaca o *Random Forest* (RF), um algoritmo classificador de conjunto que trabalha com múltiplas árvores de decisão, selecionando aleatoriamente subconjuntos de amostras e variáveis de interesse, conseguindo lidar agilmente com dados de grandes dimensões e múltiplas colinearidades (Belgiu e Drăgu, 2016). O *Random Forest* tem várias aplicações na área agrícola, como diferenciação entre culturas de interesse e plantas daninhas (Gao *et al.*, 2018), monitoramento e estimação de produtividade de culturas (Marconi *et al.*, 2024), estimação do teor de umidade de plantas (Impollonia *et al.*, 2022) e predição de produtividade de culturas usando dados de múltiplas fontes (Jhajharia e Mathur, 2023).

Na literatura não encontramos informações sobre a avaliação do controle de plantas daninhas por herbicidas com uso de imagens e aprendizado de máquina. Assim, analisamos no presente estudo a geração de modelos de predição, tendo índices de vegetação como variáveis de entrada, capazes de estimar com precisão a eficiência de controle de *U. brizantha* pelo glyphosate por meio de imagens obtidas por *smartphone*. Os modelos gerados foram treinados e validados com dados de avaliações tradicionais baseados em notas de controle (Frans, 1972) e na biomassa remanescente pós aplicação do herbicida (Oliveira *et al.*, 2024). A geração de modelos permite a predição da eficiência de controle do herbicida usado, com potencial de aplicação em avaliações de campo com vantagens sobre os métodos tradicionais utilizados. Os objetivos do estudo são: (1) Gerar índices de vegetação a partir de imagens de plantas de *U. brizantha* tratadas com diferentes doses de glyphosate com uso de imagens obtidas por *smartphone*. (2) Desenvolver e treinar modelos com uso de *Random Forest* como método de aprendizado de máquina, tendo os índices de vegetação como variáveis de entrada, em vistas a estimar a eficiência de controle de *U. brizantha* pelo glyphosate. (3) Validar os modelos de predição da eficiência de controle por herbicidas baseados em imagens obtidas por *smartphone* frente aos métodos tradicionais de avaliação da eficiência de controle de herbicidas.

Materiais e Métodos

Experimento de campo e obtenção de dados

A área utilizada para avaliação do controle das plantas pelo herbicida é pertencente à Fazenda Experimental Hamilton de Abreu Navarro (FEHAN) do Instituto de Ciências Agrárias da UFMG, na cidade de Montes Claros, estado de Minas Gerais, Brasil (coordenadas geográficas 16° 40' 49,4" S e 43° 50' 20,1" W), com infestação uniforme de *Urochloa brizantha*. Para realizar o controle, aplicaram-se as doses de 144, 288, 576, 864, 1152 e 1440 g e.a. ha⁻¹ de glyphosate, mais uma testemunha sem aplicação de herbicida. A área experimental total foi dividida em sete faixas de 5 x 30 m, sendo cada dose aplicada em uma faixa. Cada faixa foi dividida em 20 parcelas de 7,5 m² (5 x 1,5 m).

As plantas da área foram roçadas e deixadas em livre crescimento por 60 dias. A aplicação das doses de glyphosate foi realizada sobre as plantas de *U. brizantha* quando essas atingiram entre $40,4 \pm 0,87$ cm de altura. A aplicação foi realizada com pulverizador costal munido de lança com ponta de pulverização (modelo TTI11002, Teejet, Wheaton, USA) e válvula de pressão constante de 200 kPa (modelo U7466.00, Guarany, Itu, Brasil), calibrada para aplicação de $98,5 \text{ L ha}^{-1}$. Durante a aplicação, as condições ambientais médias apresentavam velocidade do vento de $2,9 \text{ km h}^{-1}$, temperatura de $19,1^\circ\text{C}$ e umidade relativa do ar de 68%.

As avaliações de eficácia do controle em cada parcela ocorreram aos 7, 15 e 30 dias após a aplicação do herbicida (DAH), utilizando avaliação visual com escala de notas, conforme Frans *et al.* (1972). Cada parcela recebeu uma nota de controle de 0 a 100% de três avaliadores experientes, em que 0 (zero) significa nenhum dano visível e 100 significa a morte da planta. A nota de cada parcela foi a média das notas desses avaliadores para cada parcela. Também aos 7, 15 e 30 DAH foram obtidas imagens de cada parcela, utilizando a câmera de um *smartphone* (modelo Poco X3 Pro, Xiaomi, Beijing, China) equipado com o sensor de câmera Sony IMX 582 de 48 MP (modelo IMX 582, Sony, Pathumthani, Tailândia). As imagens foram capturadas com uso de um suporte de madeira projetado para segurar o *smartphone* e manter a câmera estável (Figura 1), sempre no período da tarde, devido à menor variação de luminosidade no local. O suporte foi movido de parcela em parcela, tirando duas fotos por parcela, de maneira que as imagens representassem a área da parcela da melhor forma possível, isto é, buscando capturar toda a área da parcela com exceção das bordas (0,5 m para a direita e 0,5 m para a esquerda). A altura de captura das imagens foi de 1,30 m, buscando manter a posição da câmera em 90° em relação ao solo. O *smartphone* foi configurado para a obtenção das imagens na resolução de 4000×3000 pixels, capturando as imagens no modo Pro (manual), com configurações de EV (Valor de exposição) em 0 (zero), ISO em 200, foco infinito, WB (balanço de branco) em 5200 K e S (Velocidade do obturador) em $1/2500 \text{ s}$.



Figura 1. Suporte projetado para captura das imagens em cada parcela após a aplicação do herbicida.

Após a última avaliação de controle e a última sessão de fotos (30 DAH), coletou-se amostras representativas das plantas de cada parcela, a fim de determinar a massa seca (dessecada pelo herbicida) da parte aérea das plantas de *U. brizantha*. Para a definição da área de amostragem em cada parcela, utilizou-se um quadrado de 1 m². Após a coleta, as amostras foram separadas em material vivo e material morto (dessecado pelo herbicida). Esses materiais foram colocados em sacos de papel kraft e levados à estufa para secagem a 65°C por 72 horas. Depois, pesou-se a massa seca dos materiais e calculou-se o que foi considerado como controle real (material morto) pelo glyphosate, conforme Equação 1.

$$Controle\ real = \frac{Material\ Morto}{Material\ Morto + Material\ Vivo} \quad (Equação\ 1)$$

Análise computacional das imagens

Tratamento e segmentação das imagens

Todas as análises computacionais foram feitas com o auxílio do software R (R Core Team, 2024). Para a análise das imagens (Figura 2), foi utilizado o pacote *ExplImage* (Azevedo, 2024). Para importar as imagens no software R, foi utilizada a função *read_image()*. A fim de ampliar o banco de dados, cada imagem foi dividida em quatro.

Para isso, foi utilizada a função *crop_image()*. As 3360 imagens obtidas (20 parcelas x 7 doses x 2 fotos por parcela x 4 replicatas x 3 avaliações) foram divididas em duas amostras, sendo uma de treinamento e outra de validação. Para compor a amostra de treinamento, foram utilizadas 2352 imagens (70%) selecionadas aleatoriamente, as demais imagens compuseram a amostra de validação. Para a segmentação das imagens, a fim de separar os pixels correspondentes às plantas (*foreground*) e solo (*background*), considerou-se o índice VARI (Gitelson *et al.*, 2002) e o algoritmo de Otsu (Otsu, 1979) por meio das funções *gray_scale()* e *segmentation()*.

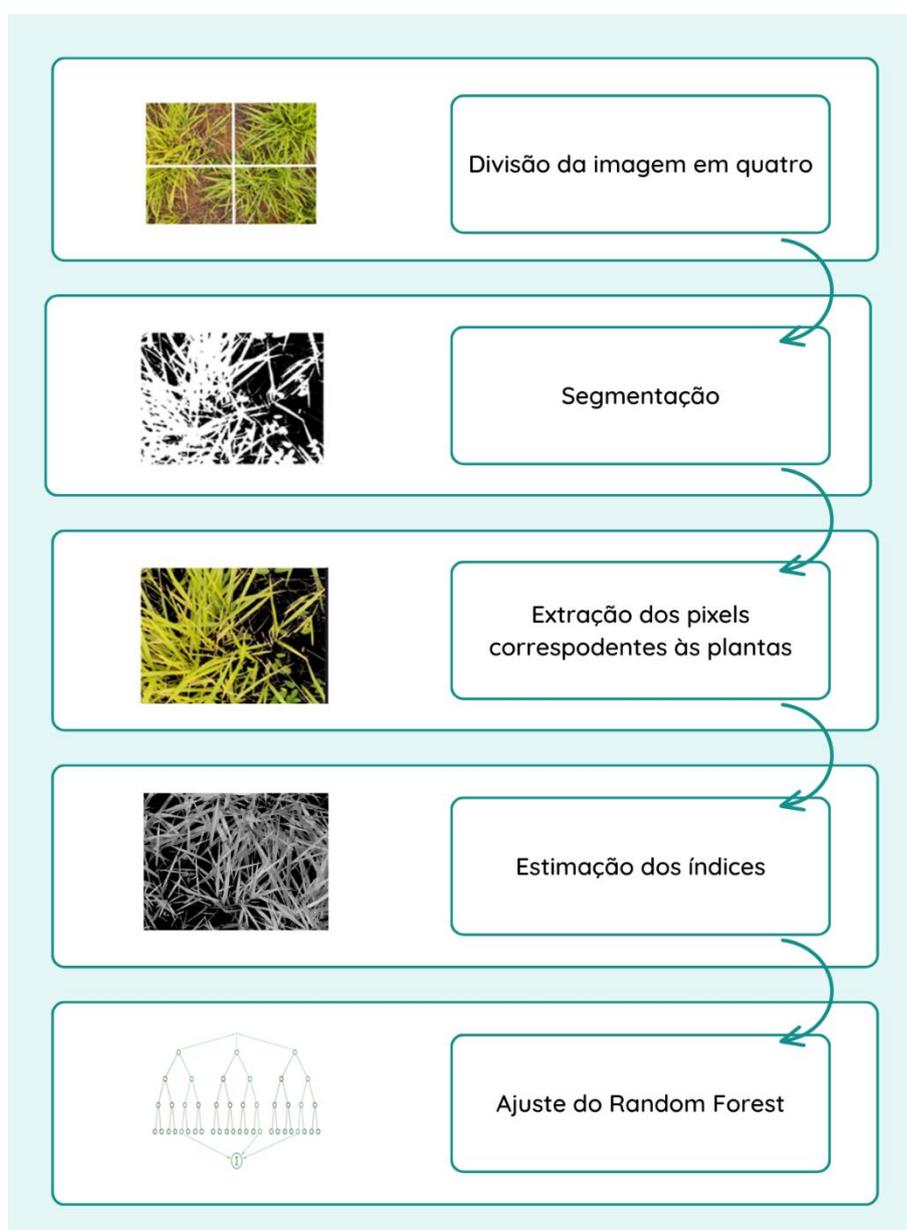


Figura 2. Fluxograma dos passos envolvidos na análise de imagens por *Random Forest* na avaliação do controle de *Urochloa brizantha* com glyphosate.

Obtenção de índices e ajuste do modelo

Após a segmentação, foram estimados 27 índices (Tabela 1) para todos os pixels correspondente às plantas (*foreground*). Para cada imagem, foi computada a média dos pixels para os índices estimados. Para a obtenção dos índices, foi utilizada a função *gray_scale()*. Posteriormente, foi feita a normalização de cada índice para os valores obtidos nas imagens. Esta etapa é necessária para que nenhuma variável tenha mais importância que a outra devido apenas à diferença nas escalas. Para isso, foi utilizada a função *normalizeData()* do pacote *RSNNS* (Bergmeir e Benitez, 2012).

Tabela 1. Índices estimados em imagens obtidas por *smartphone* na avaliação do controle de *Urochloa brizantha* com glyphosate.

Índices	Estimador	Referência
<i>r</i>	Banda do vermelho (r)	Azevedo, 2024
<i>g</i>	Banda do verde (g)	Azevedo, 2024
<i>b</i>	Banda do azul (b)	Azevedo, 2024
<i>rg</i> (mean of red and green)	$(r+g)/2$	Azevedo, 2024
<i>rb</i> (mean of red and blue)	$(r+b)/2$	Azevedo, 2024
<i>gb</i> (mean of green and blue)	$(g+b)/2$	Azevedo, 2024
<i>rgb</i> (mean of red, green and blue)	$(r+g+b)/3$	Olivoto, 2022
<i>r/g</i> (red/green ratio)	r/g	Gamon e Surfus, 1999
<i>r/b</i> (red/blue ratio)	r/b	Zakaluk e Ranjan, 2008
<i>g/r</i> (green/red ratio)	g/r	Zakaluk e Ranjan, 2008
<i>g/b</i> (green/blue ratio)	g/b	Zakaluk e Ranjan, 2008
<i>b/r</i> (blue/red ratio)	b/r	Zarco-Tejada <i>et al.</i> , 2005

<i>b/g (blue/green ratio)</i>	b/g	Zarco-Tejada <i>et al.</i> , 2005
<i>S (Saturation)</i>	$((r+g+b)-3b)/(r+g+b)$	Zakaluk e Ranjan, 2008
<i>BI (Brightness Index)</i>	$\sqrt{(r^2+g^2+b^2)/3}$	Richardson e Wiegand, 1977
<i>BIM</i>	$\sqrt{(2r+2g+2b)/3}$	Olivoto, 2022
<i>SCI (Soil Color Index)</i>	$(r-g)/(r+g)$	Mathieu <i>et al.</i> , 1998
<i>GLI (Green Leaf Index)</i>	$(2g-r-b)/(2g+r+b)$	Louhaichi <i>et al.</i> , 2001
<i>HI (Hue Index)</i>	$(2r-g-b)/(g-b)$	Escadafal <i>et al.</i> , 1994
<i>NGRDI (Normalized Green Red Difference Index)</i>	$(g-r)/(g+r)$	Tucker, 1979
<i>SI (Spectral Slope Saturation Index)</i>	$(r-b)/(r+b)$	Escadafal <i>et al.</i> , 1994
<i>VARI (Visible Atmospherically Resistant Index)</i>	$(g-r)/(g+r-b)$	Gitelson <i>et al.</i> , 2002
<i>HUE (Overall Hue Index)</i>	$\text{atan}(2(b-g-r)/30,5(g-r))$	Escadafal <i>et al.</i> , 1994
<i>MGRVI (Modified Green Red Vegetation Index)</i>	$(g^2-r^2)/(g^2+r^2)$	Bendig <i>et al.</i> , 2015
<i>MPRI (Modified Photochemical Reflectance Index)</i>	$(g-r)/(g+r)$	Yang <i>et al.</i> , 2008
<i>ExG (Excess Green)</i>	$(2*g-r-b)$	Woebbecke <i>et al.</i> , 1995
<i>RGBVI (Red Green Blue Vegetation Index)</i>	$(g^2-b*r)/(g^2+b*r)$	Bendig <i>et al.</i> , 2015

A fim de ajustar modelos para a predição da nota visual de controle e da massa vegetal morta pelo herbicida (controle real) associada a cada parcela, utilizou-se a

metodologia *Random Forest* (RF). Para isso, utilizou-se o pacote *randomForest* (Liaw e Wiener, 2002) considerando-se como variáveis de entrada os 27 índices estimados. Para testar a importância de cada um dos índices no ajuste do modelo, utilizou-se a função *importance()*. A fim de melhorar a precisão, a robustez e a generalização do modelo, foi usado o método ensemble. Para isso, foram ajustados 100 modelos de RF e, posteriormente, considerou-se a média da variável de saída correspondente a cada imagem.

Análise estatística

Todas as análises estatísticas foram feitas com o auxílio do software R (R Core Team, 2024). Para o estudo da associação existente entre os índices, foi estimada a correlação de Pearson com o auxílio da função *cor()* do pacote *stats* (R Core Team, 2024). Para a apresentação destas estimativas de correlação por meio de um gráfico, utilizou-se o pacote *corrplot* (Wei e Simko, 2021). A fim de verificar a associação entre os valores de cada índice e as variáveis dependentes (nota visual e massa seca (controle real)) estimou-se a correlação de Pearson entre eles. Também, calculou-se o coeficiente de determinação a partir dessas correlações. Esses coeficientes de correlação e de determinação foram apresentados por meio de gráfico de barras com uso do pacote *ggplot2* (Wickham, 2016).

A eficiência do modelo de *Random Forest* ajustado foi verificada pelo coeficiente de determinação obtido entre os valores reais e preditos, tanto para a amostra de validação como para a de treinamento. Foram ajustados modelos de regressão polinomial de primeiro grau com o auxílio da função *lm()* do pacote *stats* e os respectivos valores obtidos do coeficiente de determinação r^2 (R Core Team, 2024). Para apresentar estes dados, foram gerados gráficos de dispersão com o auxílio do pacote *ggplot2* (Wickham, 2016). Já para apresentar os dados das importâncias dos índices no ajuste, foram utilizados gráficos de barra com uso deste mesmo pacote.

Também foi analisada a robustez dos modelos ao *overfitting*. O *overfitting* ocorre quando a árvore de decisão se torna dependente de aspectos irrelevantes encontrados nos dados de treinamento, de forma que o seu poder de lidar com dados diferentes (novos dados) é prejudicado (Bramer, 2013), levando a um mal desempenho do modelo na validação. Portanto, um desempenho ruim nas amostras de validação indica problemas com *overfitting*, enquanto um desempenho satisfatório nessas amostras

indica a robustez do modelo contra esse fenômeno e sua capacidade de generalização para novos dados.

Resultados

O controle da população de plantas daninhas foi excelente (>91%) em resposta à aplicação das duas maiores doses de glyphosate aos 30 DAH (Figura 3). O comportamento da linha de tendências entre o controle por avaliação visual por escala de nota foi similar ao observado pela avaliação da massa vegetal dessecada pelo herbicida, considerada como controle real (Figura 3).

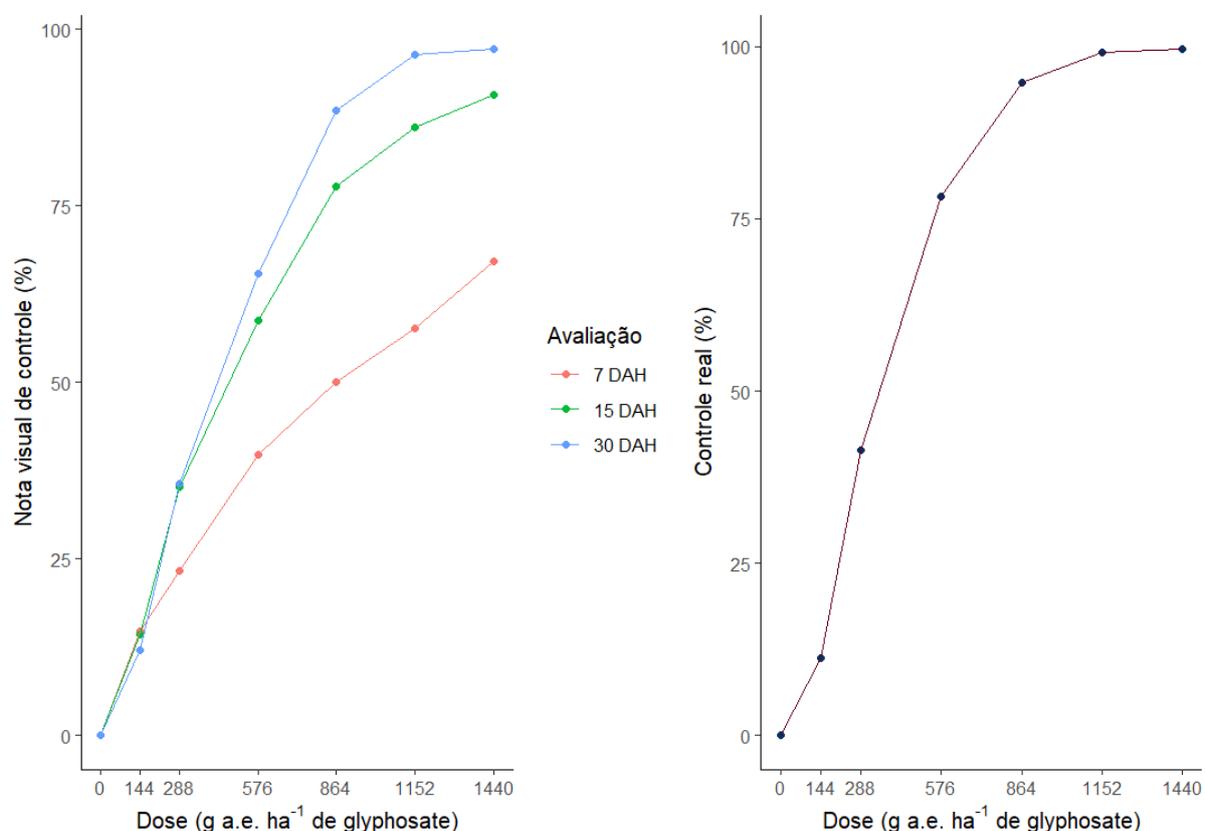


Figura 3. Valores obtidos para notas visuais de controle e controle real (material morto pelo herbicida) para controle de *Urochloa brizantha* com diferentes doses de glyphosate.

Os índices de vegetação com fórmulas que propuseram relações semelhantes (razões entre as mesmas bandas, destaque para bandas específicas, etc.) tiveram alta correlação direta entre si, como os pares GLI e RGBVI (destacaram a banda do verde em detrimento das demais de forma semelhante) e NGRDI e VARI (destaque para banda do verde e razão semelhante entre bandas). Índices que propuseram relações invertidas

tiveram alta correlação negativa, como o par SCI e NGRDI (um destacou a banda do vermelho em relação à banda do verde e o outro o inverso) e o par HI e GLI (um destacou a banda do verde e outro a banda do vermelho) (Figura 4).

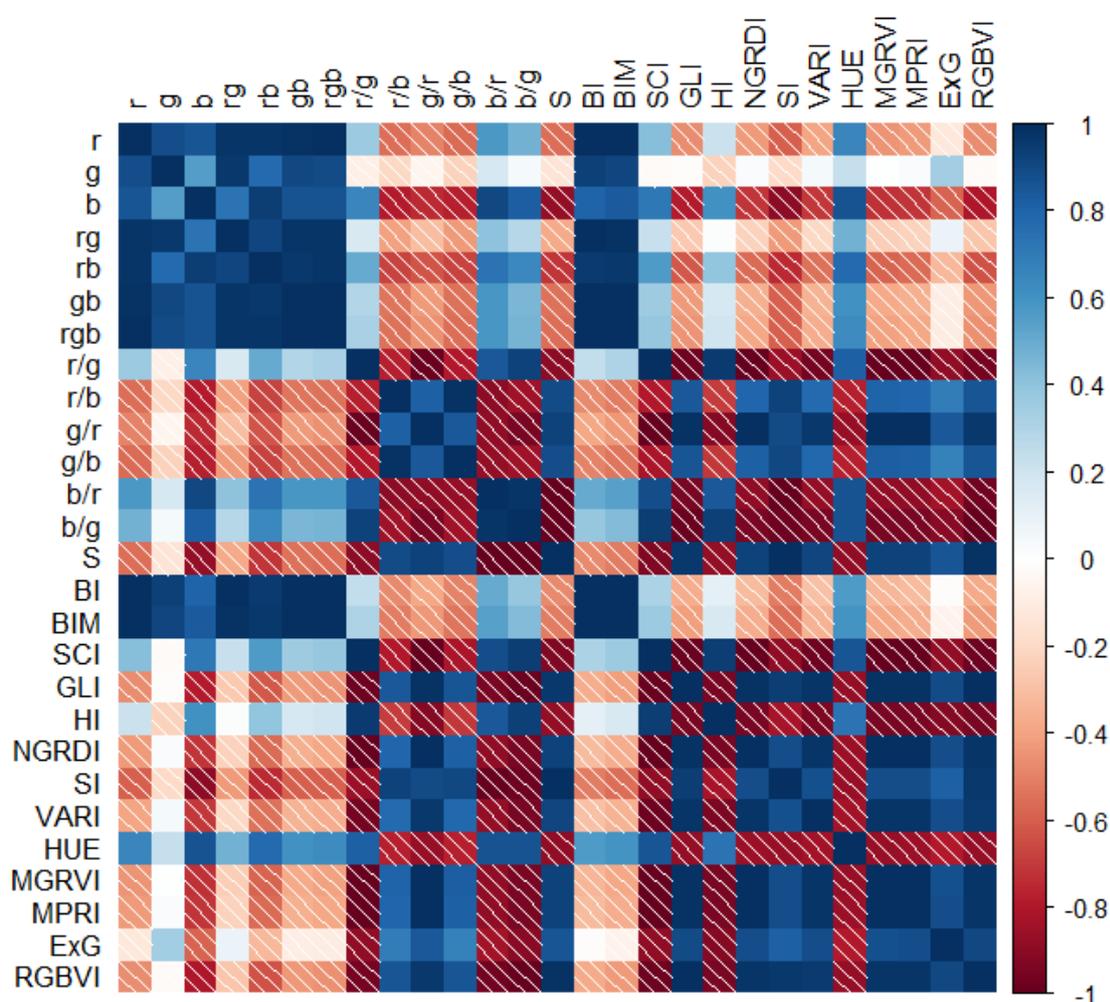


Figura 4. Estimativas da correlação de Pearson entre índices obtidos em imagens para a avaliação do controle de *Urochloa brizantha* com glyphosate.

A correlação de Pearson entre cada índice de vegetação e as notas visuais de controle foi calculada, conforme apresentado na Figura 5. Os índices S, ExG, g/r, VARI, MGRVI, MPRI, NGRDI, RGBVI e GLI, representados em barras vermelho escuro (Figura 5a), apresentaram alta correlação inversamente proporcional com as notas de controle (acima de 0,90) e coeficientes de determinação entre 82 e 89% (Figura 5b). Os índices SCI, b/g, r/g e HI apresentaram correlação diretamente proporcional acima de 0,90 com as notas de controle e coeficientes de determinação entre 83 e 87% (Figura 5). Para os

índices SI, b/r e HUE, foram obtidos coeficientes entre 72 e 77%. Para todos os outros índices observaram-se coeficientes de determinação abaixo de 60% (Figura 5b).

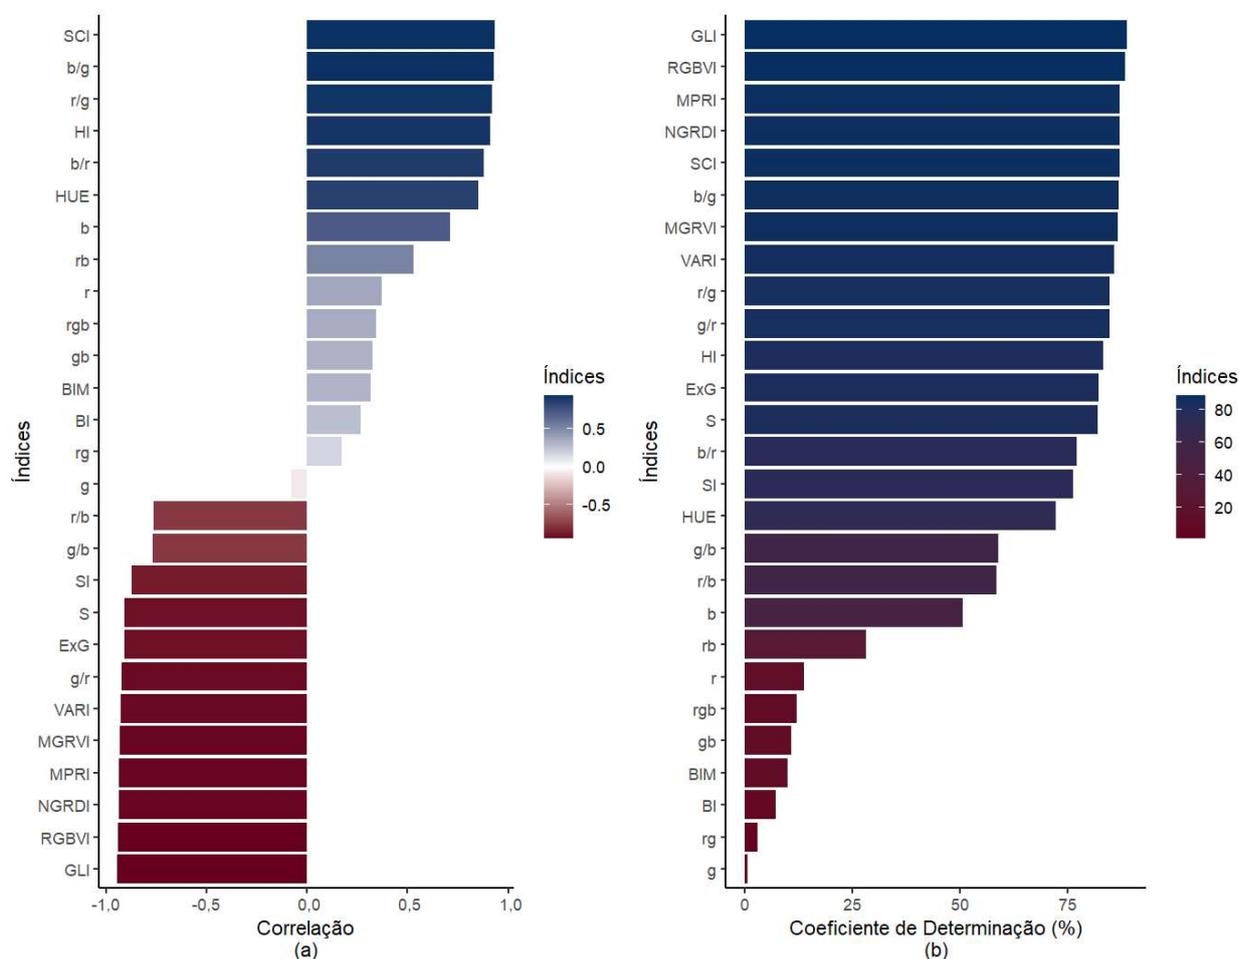


Figura 5. Estimativas da correlação de Pearson (a) e coeficiente de determinação (b) no estudo da associação entre os índices obtidos com uso de imagens de *smartphone* e o controle obtido por notas visuais, baseado na escala de Frans *et al.* (1972), para *Urochloa brizantha* submetida a aplicação de glyphosate.

A análise de regressão linear, para a avaliação da qualidade do ajuste do *Random Forest*, mostrou uma associação direta significativa entre as notas de controle previstas pelo modelo e as notas observadas no treinamento, apresentando um coeficiente de determinação de 91,76%, indicando alta capacidade do modelo em gerar previsões com base nas imagens (Figura 6a). Para a amostra de validação, observou-se um valor ainda maior para o coeficiente de determinação (92,31%), confirmando o potencial do modelo em fazer previsões da nota de controle com base em imagens de *smartphone* (Figura 6b).

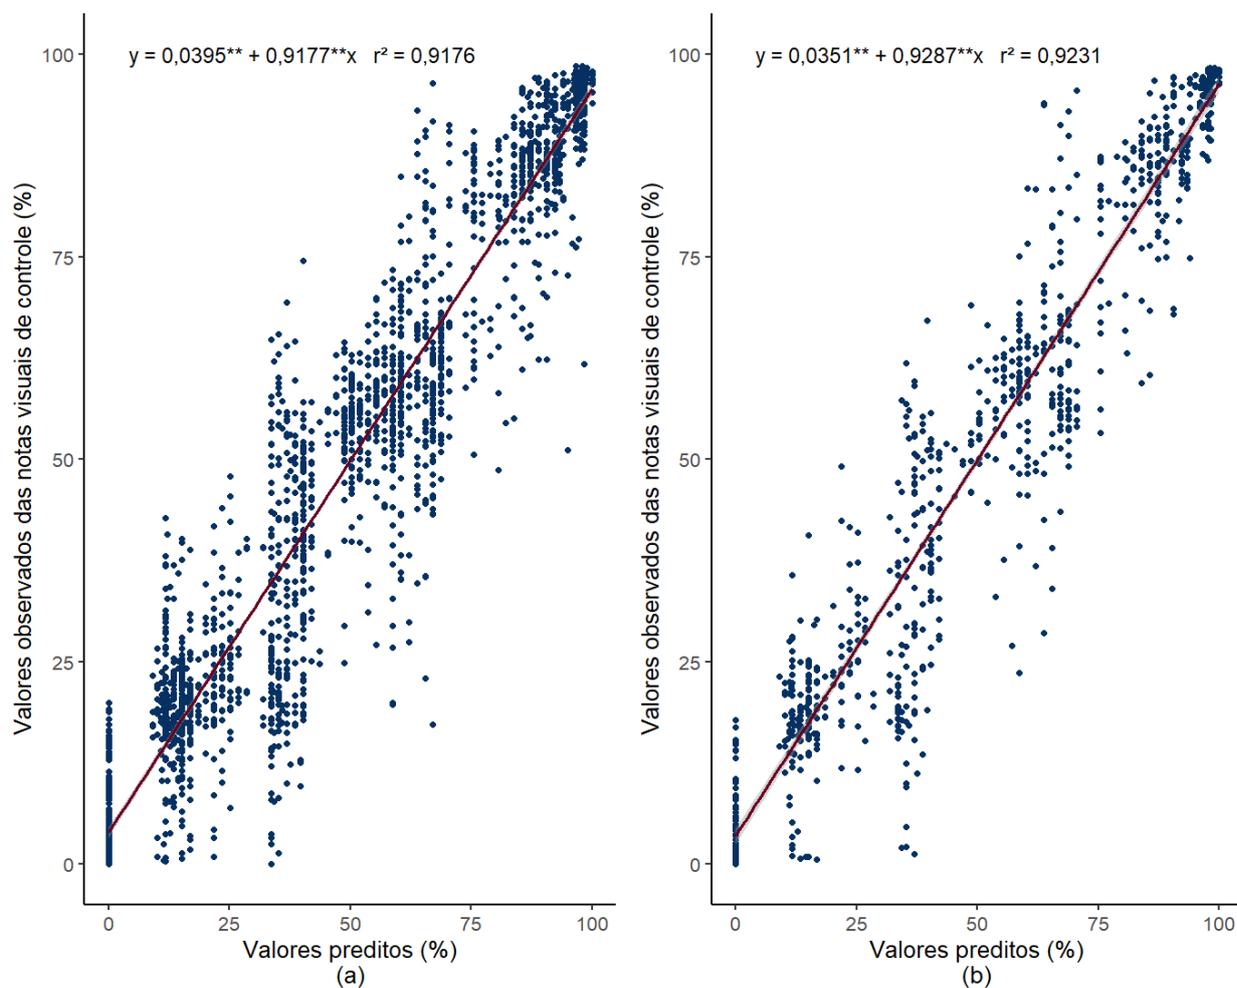


Figura 6. Avaliação da qualidade do ajuste do *Random Forest* na estimação das notas associadas à avaliação do controle de *Urochloa brizantha* com glyphosate para a amostra de treinamento (a) e validação (b).

A importância estatística de cada índice de vegetação para o modelo é apresentada na Figura 7. Para esse modelo, os dois índices mais importantes foram o GLI e o HI, sendo a importância dos demais inferior a 10% para o modelo ajustado (Figura 7).

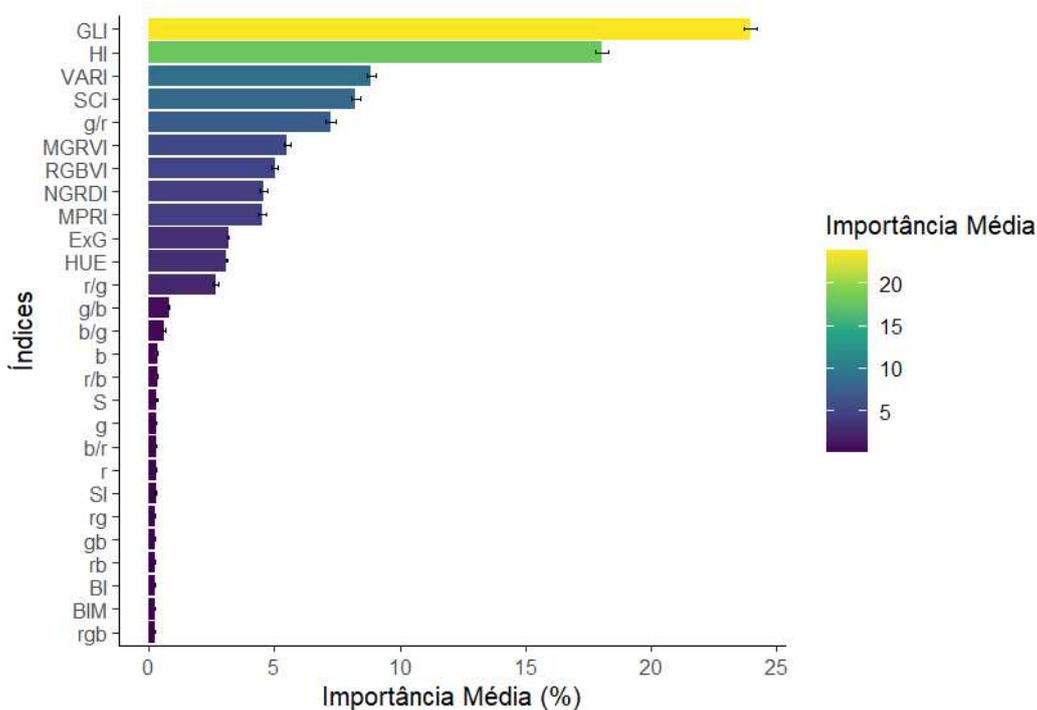


Figura 7. Importância dos índices no ajuste do *Random Forest* e intervalo de confiança da média a 5% de significância pelo teste t na estimação das notas associadas à avaliação do controle de *Urochloa brizantha* com glyphosate.

Para as estimativas da correlação de Pearson entre cada índice e o nível de controle real (material morto pelo herbicida), observou-se alta correlação inversamente proporcional com o controle real (acima de 0,90) e coeficientes de determinação entre 84 e 89% para os índices SI, VARI, ExG, MPRI, NGRDI, g/r, MGRVI, S, GLI e RGBVI (Figura 8). Para os índices b/g, SCI, b/r, HI e r/g, observou-se correlação diretamente proporcional acima de 0,90 com o controle real e coeficientes de determinação entre 82 e 88% (Figura 8). Os índices HUE, g/b e r/b apresentaram coeficientes de determinação entre 67 e 77%. Todos os outros índices apresentaram coeficientes de determinação inferiores a 60% (Figura 8b).

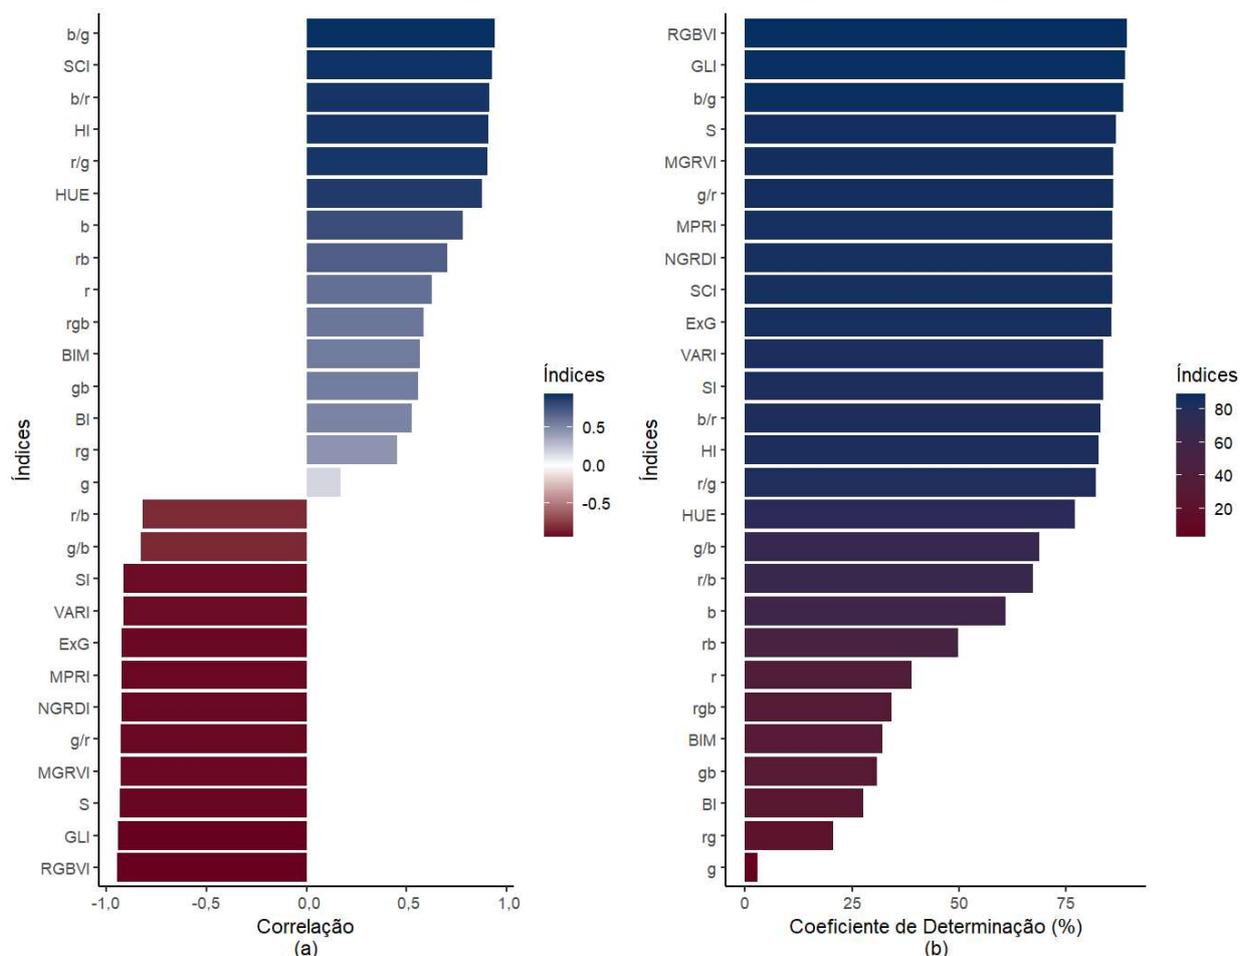


Figura 8. Estimativas da correlação de Pearson (a) e coeficiente de determinação (b) no estudo da associação entre índices obtidos em imagens e o controle real (material morto) de *Urochloa brizantha* com glyphosate.

A avaliação da qualidade do ajuste do *Random Forest* para a estimação do controle real indicou correlação substancial entre os valores de controle real estimados pelo modelo e os valores de controle real observados no treinamento, apresentando coeficiente de determinação do ajuste de 88,05% (Figura 9a). Para a amostra de validação, o modelo foi ainda mais eficiente, estimando com ainda mais precisão os valores de controle real, verificando-se 90,33% de capacidade do modelo em explicar variações na variável dependente e alta precisão nas previsões feitas com base nos índices de vegetação (Figura 9b), significando que os valores de controle calculados pelo modelo são muito próximos dos valores de controle real obtidos pela massa do material morto de *U. brizantha*.

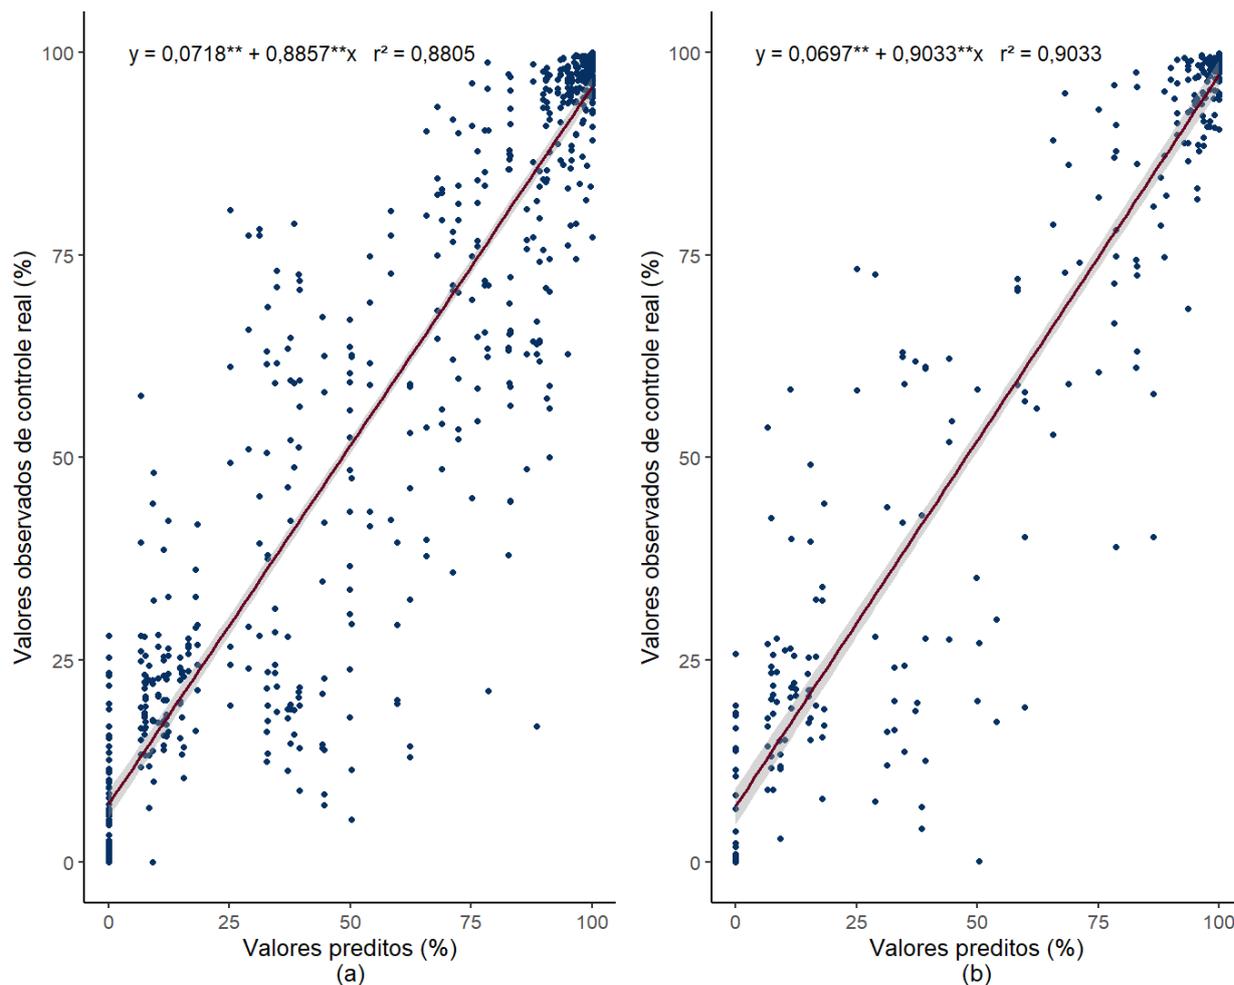


Figura 9. Avaliação da qualidade do ajuste do *Random Forest* na estimação do controle real (massa de *Urochloa brizantha* morta pela ação do herbicida) pelo glyphosate para a amostra de treinamento (a) e validação (b).

A importância estatística de cada índice para o modelo de estimação do controle real é apresentada na Figura 10. Os índices HI, b/g e RGBVI foram os mais importantes para o modelo, ou seja, tiveram maior impacto na capacidade do modelo de fazer previsões.

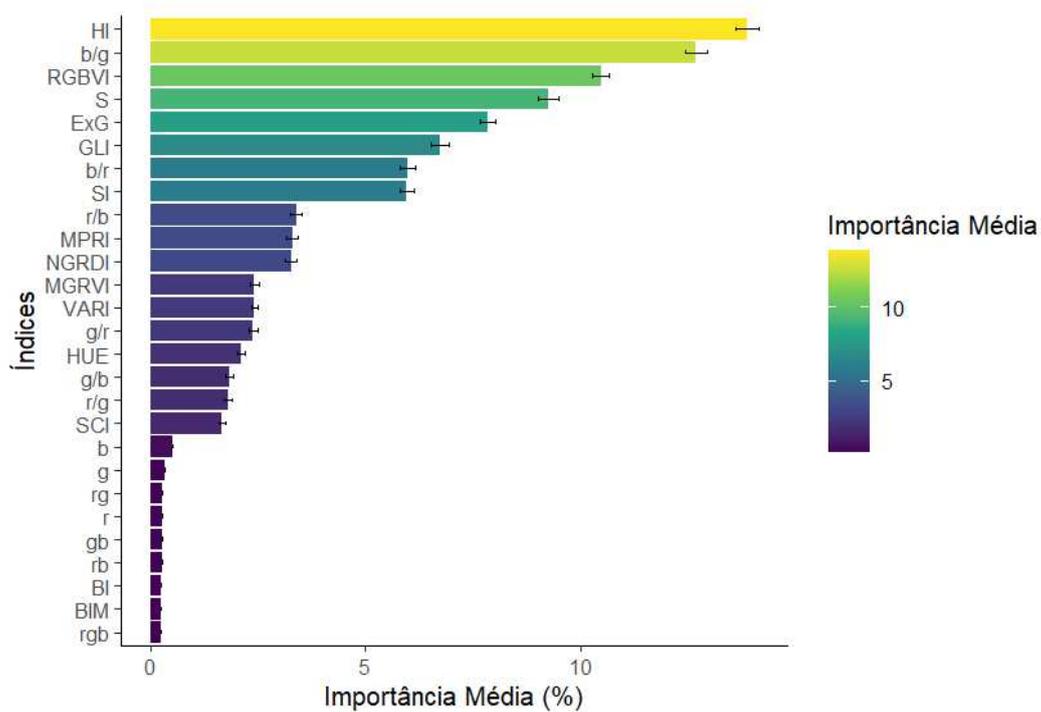


Figura 10. Importância dos índices no ajuste do *Random Forest* e intervalo de confiança da média a 5% de significância pelo teste t na estimação do controle real (massa de *Urochloa brizantha* morta pela ação do herbicida) pelo glyphosate.

Discussão

O uso de análise de imagens de *smartphone* por *Random Forest* (RF), tendo índices de vegetação como variáveis de entrada, possibilitou desenvolver modelos capazes de avaliar com precisão o controle das plantas daninhas pelo herbicida. Esta pesquisa traz resultados inéditos na avaliação de controle de plantas daninhas por glyphosate com uso de imagens. Alguns trabalhos usaram análise de imagens com RF com plantas daninhas para identificação de espécies (Mkhize *et al.*, 2023; Gao *et al.*, 2018); mapeamento de infestação (Panduangnat *et al.*, 2024; Anderegg *et al.*, 2023) e monitoramento de sistemas de manejo (Caras *et al.*, 2024), mas, até onde encontrado pelos autores deste estudo, nenhum com objetivo de avaliar a eficiência do controle de plantas daninhas por herbicidas utilizando imagens de *smartphone*.

A matriz de correlação entre índices (Figura 4) permitiu identificar índices redundantes para a avaliação de controle, considerando que índices com alta correlação entre si (positiva ou negativa) têm utilidade similar para a avaliação de controle. Assim, caso ocorra algum problema em um ou mais índices, pode-se recorrer a índices similares a eles. Por exemplo, os casos dos índices r/g e RGBVI, que possuem alta correlação inversamente proporcional entre si, e o par r/g e SCI, que possui alta correlação diretamente proporcional entre si. Com isso, se o índice r/g, por exemplo, não estiver disponível, pode ser substituído por um dos seus índices redundantes (Figura 4).

De acordo com os gráficos de correlação linear de Pearson entre os índices e as notas de controle (Figura 5) e entre os índices e o controle real (massa morta de planta daninha pelo efeito herbicida), mostrado na Figura 8, constata-se que a maioria dos índices utilizados são úteis para avaliação do controle por meio das imagens. O uso de mais índices com boa correlação com a variável resposta contribuiu significativamente para o bom ajuste do RF, como observado por Ramos *et al.* (2020).

Os modelos desenvolvidos com árvores de decisão alcançaram alta capacidade em fazer previsões com base nas imagens de *smartphone* (r^2 acima de 0,90 para o modelo de previsão de notas de controle e em média 0,89 para o modelo de previsão que utilizou dados do controle real) e se mostraram robustos contra o *overfitting*, tendo ótimo desempenho tanto na amostra de treinamento como na amostra de validação (Figuras 6 e 9). Portanto, o bom desempenho dos modelos propostos com os dados de validação confirma sua capacidade de generalização e aplicação em novos dados (Figuras 6 e 9). Apesar de vários algoritmos de aprendizado de máquina poderem ter

problemas com *overfitting* (inclusive o RF), o RF é considerado preciso e robusto contra esse tipo de problema, devido à sua aleatoriedade, ao grande número de árvores de decisão envolvidos no processo e à independência entre elas (Belgiu e Drăgu, 2016; Zaimes *et al.*, 2019; Jhajharia e Mathur, 2023).

Índices de vegetação com maior importância estatística tiveram maior impacto na capacidade do modelo de fazer previsões, ou seja, permitiram estimar com maior precisão o nível de controle das plantas. Isso permite selecionar quais índices são mais importantes para o modelo e, conseqüentemente, quais se adequam melhor ao objetivo de prever o nível de controle. Além disso, é possível otimizar futuros processos, eliminando índices de vegetação pouco úteis para a estimação de modelos de *Random Forest* para o fim de avaliação de eficácia do controle de plantas daninhas com glyphosate.

Observando-se os gráficos de correlação (Figuras 5 e 8), é possível perceber que os índices calculados por meio de equações lineares tiveram resultados inferiores aos índices calculados com razões, isso provavelmente se deve ao fato de que as operações de divisão entre os componentes de cor tornam os índices mais robustos a variações de luz em relação aos índices que usam apenas operações lineares, como discutido por Salazar-Reque *et al.* (2023) no contexto de análise temporal de índices de vegetação calculados a partir de imagens aéreas RGB. A presença desses índices como variáveis de entrada pode explicar o porquê os modelos foram robustos contra a variação de luminosidade das imagens, mantendo sua capacidade de estimação do controle, mesmo com imagens consideravelmente mais claras ou mais escuras.

Apesar dos bons resultados na estimação dos modelos de RF, é importante dizer que a precisão do modelo depende do sucesso da segmentação das imagens. No caso deste estudo, o algoritmo de Otsu foi utilizado como método de segmentação, que assume que existe uma variação dos valores de pixels entre diferentes classes de objetos (Otsu, 1979). Se as imagens capturadas tiverem muitas plantas que não são de interesse para a avaliação de controle ou se estiverem presentes objetos que possam ser confundidos com uma planta saudável ou morta, de forma que dificulte um contraste bem definido entre planta de interesse e fundo (objetos ou outras plantas irrelevantes para a avaliação), a segmentação pode enfrentar problemas, reduzindo a precisão dos índices de vegetação e, conseqüentemente, das estimativas do modelo. Entretanto, esse problema pode ser resolvido buscando-se focar a câmera diretamente para a planta de

interesse, evitando a presença de objetos ou outras plantas de cores similares na imagem.

Outro ponto importante é a generalização dos modelos para a avaliação de controle de outras plantas daninhas e/ou com uso de outros herbicidas. Considerando-se que a avaliação proposta com uso dos modelos de RF baseia-se na variação de cor de uma planta para dizer se ela está saudável ou morta, utilizando indicadores matemáticos (índices de vegetação) para realizar essa medição, é possível inferir que os modelos gerados se aplicam a qualquer planta que apresente variação de cor entre os estados de saudável e morta (como a cor verde quando saudável e próxima de cinza quando morta). Quanto aos herbicidas, por provocarem a morte da planta e, em geral, não variarem entre si na característica de cor da planta, isto é, não alterarem significativamente a variação de cor já esperada de uma planta saudável à morta, também é possível dizer que os modelos propostos também se aplicam a plantas dessecadas com diferentes herbicidas, como o dicamba e o glufosinato de amônio (Ghimire *et al.*, 2023), o atrazine (Traxler *et al.*, 2023), o 2,4 D (Brochado *et al.*, 2022) e o próprio glyphosate (Ferreira *et al.*, 2023), por apresentarem sintomas muito parecidos no que tange à alteração de cor das plantas com o progresso de seus efeitos sobre elas.

Acredita-se que o estágio de desenvolvimento da planta também não altere a capacidade de predição de controle do modelo, considerando que os herbicidas podem ter menos sucesso no controle de acordo com o estágio de desenvolvimento da planta (Ferreira *et al.*, 2023), isso somente implicaria menor dano a ela e, caso houver variação de cor na planta (mesmo que pequena), isso seria detectado pelo modelo, principalmente por ser treinado com índices de vegetação, que são utilizados exatamente para capturar variações de cor nas plantas.

Também é importante destacar a facilidade de obtenção das imagens com *smartphone*. Em muitos casos, a obtenção de imagens para aplicações da inteligência artificial na agricultura emprega o uso de aeronaves não tripuladas acopladas a câmeras específicas (Jin *et al.*, 2024; Ribeiro *et al.*, 2024; Pang *et al.*, 2020; Yang *et al.*, 2021; Enciso *et al.*, 2019), o que dificulta o uso por grande parte dos produtores e aumenta o custo de implantação, enquanto com uso do *smartphone*, a obtenção das imagens se torna mais fácil e acessível.

Os resultados do presente estudo confirmam a efetividade e precisão do *Random Forest* na avaliação da eficiência no controle de plantas daninhas por glyphosate, com uso dos índices de vegetação como variáveis de entrada. Além disso, o uso do

smartphone na captura das imagens torna a obtenção dos dados mais simples e pode facilitar a popularização do seu uso na avaliação de controle de plantas daninhas, com a criação de aplicativos que podem ser baixados facilmente para o dispositivo, em que o usuário pode fazer o upload da imagem e ter o valor da nota de controle instantaneamente. A avaliação via *smartphone* proporcionaria maior confiabilidade e rapidez à avaliação de controle, independente do avaliador, evitando os problemas recorrentes da subjetividade humana e tornando o processo mais barato, considerando que o uso de um aplicativo móvel é menos oneroso que a contratação de um profissional para a avaliação. Os modelos podem ser implementados diretamente no aplicativo, já treinados, sendo possível realizar o processamento mesmo sem conexão à internet.

Conclusões

O uso do *Random Forest* como método de aprendizado de máquina e dos índices de vegetação como variáveis de entrada possibilita a criação de modelos capazes de estimar com alta precisão (r^2 acima de 0,90) a eficiência de controle de *U. brizantha* pelo glyphosate.

Os modelos desenvolvidos se mostraram robustos contra o *overfitting* e obtiveram r^2 acima de 0,90 para as amostras de validação, confirmando seu potencial de generalização e de uso em novos dados.

As imagens capturadas pelo *smartphone* atenderam satisfatoriamente ao propósito do estudo e as descobertas indicam a possibilidade de operacionalização da avaliação de controle de plantas daninhas com uso de aplicativos móveis.

REFERÊNCIAS

AGROFIT, 2024. System of Phytosanitary Pesticides of the Ministry of Agriculture, Livestock and Food Supply (MAPA) of Brazil. http://agrofit.agricultura.gov.br/agrofit_cons/principal_agrofit_cons.

Anderegg, J., Tschurr, F., Kirchgessner, N., Treier, S., Schmucki, M., Streit, B., Walter, A., 2023. On-farm evaluation of UAV-based aerial imagery for season-long weed monitoring under contrasting management and pedoclimatic conditions in wheat. *Computers and Electronics in Agriculture* 204, 107558. <https://doi.org/10.1016/j.compag.2022.107558>.

Asad, M.H., Bais, A., 2020. Weed detection in canola fields using maximum likelihood classification and deep convolutional neural network. *Information Processing in Agriculture* 7 (4), 535–545. <https://doi.org/10.1016/j.inpa.2019.12.002>.

Azevedo, A.M., 2024. ExplImage: Analysis of Images in Experiments. Cran-R. <https://cran.r-project.org/package=ExplImage>.

Belgiu, M., Drăguț, L., 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing* 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.

Benbrook, C.M., 2016. Trends in glyphosate herbicide use in the United States and globally. *Environmental Sciences Europe* 28 (1), 3. <https://doi.org/10.1186/s12302-016-0070-0>.

Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M.L., Bareth, G., 2015. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation* 39, 79–87. <https://doi.org/10.1016/j.jag.2015.02.012>.

Bergmeir, C., Benitez, J.M., 2012. Neural networks in R using the Stuttgart neural network simulator: RSNNS. *Journal of Statistical Software* 46 (7), 1–26. <https://cran.r-project.org/package=RSNNS>.

Bhatti, M.A., Syam, M.S., Chen, H., Hu, Y., Keung, L.W., Zeeshan, Z., Ali, Y.A., Sarhan, N., 2024. Utilizing convolutional neural networks (CNN) and U-Net architecture for precise crop and weed segmentation in agricultural imagery: A deep learning approach. *Big Data Research* 36, 100465. <https://doi.org/10.1016/j.bdr.2024.100465>.

Bramer, M., 2013. Avoiding overfitting of decision trees. In: BRAMER, M. Principles of data mining. Undergraduate topics in computer science. London: Springer, 121–136. https://doi.org/10.1007/978-1-4471-4884-5_9.

Brochado, M.G.D.S., Mielke, K.C., Paula, D.F.D., Laube, A.F.S., Alcántara-de La Cruz, R., Gonzatto, M.P., Mendes, K.F., 2022. Impacts of dicamba and 2,4-D drift on ‘Ponkan’ mandarin seedlings, soil microbiota and *Amaranthus retroflexus*. *Journal of Hazardous Materials Advances* 6, 100084. <https://doi.org/10.1016/j.hazadv.2022.100084>.

Caras, T., Lati, R.N., Holland, D., Dubinin, V.M., Hatib, K., Shulner, I., Keiesar, O., Liddor, G., Paz-Kagan, T., 2024. Monitoring the effects of weed management strategies on tree canopy structure and growth using UAV-LiDAR in a young almond orchard. *Computers and Electronics in Agriculture* 216, 108467. <https://doi.org/10.1016/j.compag.2023.108467>.

Chauhan, B.S., 2020. Grand challenges in weed management. *Frontiers in Agronomy* 1. <https://doi.org/10.3389/fagro.2019.00003>.

Das, T.K., Behera, B., Nath, C.P., Ghosh, S., Sen, S., Raj, R., Ghosh, S., Sharma, A.R., Yaduraju, N.T., Nalia, A., Dutta, A., Kumar, N., Singh, R., Pathak, H., Singh, R.G., Hazra, K.K., Ghosh, P.K., Layek, J., Patra, A., Paramanik, B., 2024. Herbicides use in crop production: An analysis of cost-benefit, non-target toxicities and environmental risks. *Crop Protection* 181, 106691. <https://doi.org/10.1016/j.cropro.2024.106691>.

Escadafal, R., Belghit, A., Ben-Moussa, H., 1994. Indices spectraux pour la télédétection de la dégradation des milieux naturels en Tunisie aride. In: *Actes du 6ème Symposium international sur les mesures physiques et signatures en télédétection, Val d'Isère (France)*, pp. 253–259.

Enciso, J., Avila, C.A., Jung, J., Elsayed-Farag, S., Chang, A., Yeom, J., Landivar, J., Maeda, M., Chavez, J.C., 2019. Validation of agronomic UAV and field measurements for tomato varieties. *Computers and Electronics in Agriculture* 158, 278–283. <https://doi.org/10.1016/j.compag.2019.02.011>.

Ferreira, M.F., Torres, C., Bracamonte, E., Galetto, L., 2023. Glyphosate affects the susceptibility of non-target native plant species according to their stage of development and degree of exposure in the landscape. *Science of The Total Environment* 865, 161091. <https://doi.org/10.1016/j.scitotenv.2022.161091>.

Frans, R.W., 1972. Measuring plants response. In: WILKINSON, R.E. (Ed.). *Research methods in weed science*. Puerto Rico: Weed Science Society, 28–41.

Fuglie, K., Peters, M., Burkart, S., 2021. The extent and economic significance of cultivated forage crops in developing countries. *Front. Sustain. Food Syst.*, 5. <https://doi.org/10.3389/fsufs.2021.712136>.

Gamon, J.A., Surfus, J.S., 1999. Assessing leaf pigment content and activity with a reflectometer. *New Phytologist* 143, 105–117. <https://doi.org/10.1046/j.1469-8137.1999.00424.x>.

Gao, J., Nuyttens, D., Lootens, P., He, Y., Pieters, J.G., 2018. Recognising weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery. *Biosystems Engineering* 170, 39–50. <https://doi.org/10.1016/j.biosystemseng.2018.03.006>.

Gharde, Y., Singh, P.K., Dubey, R.P., Gupta, P.K., 2018. Assessment of yield and economic losses in agriculture due to weeds in India. *Crop Protection* 107, 12–18. <https://doi.org/10.1016/j.cropro.2018.01.007>.

Ghimire, B.K., Yu, C.Y., Kim, S.H., Chung, I.M., 2023. Evaluation of pre-emergence and post-emergence herbicides for weed management in *Miscanthus sacchariflorus* and *Miscanthus sinensis*. *Phyton-International Journal of Experimental Botany* 92 (5), 1439–1467. <https://doi.org/10.32604/phyton.2023.023076>.

Gitelson, A.A., Kaufman, Y.J., Stark, R., Rundquist, D., 2002. Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment* 80 (1), 76–87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9).

Ibama - Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis, 2025. Assuntos. Químicos e biológicos. Agrotóxicos. Painéis de informações de agrotóxicos. Portal Gov.br. <https://www.gov.br/ibama/pt-br/assuntos/quimicos-e-biologicos/agrotoxicos/paineis-de-informacoes-de-agrotoxicos/paineis-de-informacoes-de-agrotoxicos#Painel-comercializacao>.

Impollonia, G., Croci, M., Martani, E., Ferrarini, A., Kam, J., Trindade, L.M., Clifton-Brown, J., Amaducci, S., 2022. Moisture content estimation and senescence phenotyping of novel *Miscanthus* hybrids combining UAV-based remote sensing and machine learning. *GCB Bioenergy* 14, 639–656. <https://doi.org/10.1111/gcbb.12930>.

Jin, Z., Guo, S., Li, S., Yu, F., Xu, T., 2024. Research on the rice fertiliser decision-making method based on UAV remote sensing data assimilation. *Computers and Electronics in Agriculture* 216, 108508. <https://doi.org/10.1016/j.compag.2023.108508>.

Jhajharia, K., Mathur, P., 2023. Prediction of crop yield using satellite vegetation indices combined with machine learning approaches. *Advances in Space Research* 72 (9), 3998–4007. <https://doi.org/10.1016/j.asr.2023.07.006>.

Liaw, A., Wiener, M., 2002. Classification and regression by randomForest. *R News* 2 (3), 18–22. <https://CRAN.R-project.org/doc/Rnews/>.

Louhaichi, M., Borman, M.M., Johnson, D.E., 2001. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International* 16 (1), 65–70. <https://doi.org/10.1080/10106040108542184>.

Marconi, A., Impollonia, G., Croci, M., Blandinières, H., Pellegrini, N., Amaducci, S., 2024. Garlic yield monitoring using vegetation indices and texture features derived from UAV multispectral imagery. *Smart Agricultural Technology* 8, 100513. <https://doi.org/10.1016/j.atech.2024.100513>.

Mathieu, R., Pouget, M., Cervelle, B., Escadafal, R., 1998. Relationships between satellite-based radiometric indices simulated using laboratory reflectance data and typical soil color of an arid environment. *Remote Sensing of Environment* 66 (1), 17–28. [https://doi.org/10.1016/S0034-4257\(98\)00030-3](https://doi.org/10.1016/S0034-4257(98)00030-3).

Mkhize, Y., Madonsela, S., Cho, M., Nondlazi, B., Main, R., Ramoelo, A., 2024. Mapping weed infestation in maize fields using Sentinel-2 data. *Physics and Chemistry of the Earth, Parts A/B/C* 134, 103571. <https://doi.org/10.1016/j.pce.2024.103571>.

Moazzam, S.I., Khan, U.S., Qureshi, W.S., Nawaz, T., Kunwar, F., 2023. Towards automated weed detection through two-stage semantic segmentation of tobacco and

weed pixels in aerial imagery. *Smart Agricultural Technology* 4, 100142. <https://doi.org/10.1016/j.atech.2022.100142>.

Nandhini, M., Kala, K.U., Thangadarshini, M., Madhusudhana Verma, S., 2022. Deep learning model of sequential image classifier for crop disease detection in plantain tree cultivation. *Computers and Electronics in Agriculture* 197, 106915. <https://doi.org/10.1016/j.compag.2022.106915>.

Novotny, E., 2022. Glyphosate, Roundup and the Failures of Regulatory Assessment. *Toxics* 10 (6), 321. <https://doi.org/10.3390/toxics10060321>.

Oerke, E.-C., 2006. Crop losses to pests. *The Journal of Agricultural Science* 144 (1), 31–43. <https://doi.org/10.1017/S0021859605005708>.

Oliveira, V.V. De, Donato, L.M.S., Ruas, M.A.O., Oliveira, J.Â.M. De, Souza, R.F., Tuffi Santos, L.D., 2024. The light intensity in the cultivation environment and the impact of glyphosate on plants of the *Urochloa* genus. *Journal of Environmental Science and Health, Part B* 59, 540–549. <https://doi.org/10.1080/03601234.2024.2381934>.

Olivoto T., 2022. Lights, camera, pliman! An R package for plant image analysis. *Methods Ecol. Evol.* 13 (4), 789–798.

Otsu, N., 1979. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics* 9 (1), 62–66.

Panduangnat, L., Posom, J., Saikaew, K., Phuphaphud, A., Wongpiche, S., Chinapas, A., Sukpancharoen, S., Saengprachatanarug, K., 2024. Time-efficient low-resolution RGB aerial imaging for precision mapping of weed types in site-specific herbicide application. *Crop Protection* 184, 106805. <https://doi.org/10.1016/j.cropro.2024.106805>.

Pang, Y., Shi, Y., Gao, S., Jiang, F., Veeranampalayam-Sivakumar, A.-N., Thompson, L., Luck, J., Liu, C., 2020. Improved crop row detection with deep neural network for early-season maize stand count in UAV imagery. *Computers and Electronics in Agriculture* 178, 105766. <https://doi.org/10.1016/j.compag.2020.105766>.

R Core Team, 2024. R: a language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>.

Raja, R., Slaughter, D.C., Fennimore, S.A., Siemens, M.C., 2023. Real-time control of high-resolution micro-jet sprayer integrated with machine vision for precision weed control. *Biosystems Engineering* 228, 31–48. <https://doi.org/10.1016/j.biosystemseng.2023.02.006>.

Ram, B.G., Oduor, P., Igathinathane, C., Howatt, K., Sun, X., 2024. A systematic review of hyperspectral imaging in precision agriculture: Analysis of its current state and future prospects. *Computers and Electronics in Agriculture* 222, 109037. <https://doi.org/10.1016/j.compag.2024.109037>.

Ramos, A.P.M., Osco, L.P., Furuya, D.E.G., Gonçalves, W.N., Santana, D.C., Teodoro, L.P.R., Silva Junior, C.A., Capristo-Silva, G.F., Li, J., Baio, F.H.R., Marcato Junior, J., Teodoro, P.E., Pistori, H.A., 2020. A random forest ranking approach to predict yield in

maize with UAV-based vegetation spectral indices. *Computers and Electronics in Agriculture* 178, 105791. <https://doi.org/10.1016/j.compag.2020.105791>.

Ribeiro, J.B., Da, R.R., Dias, J.D., Escarpinati, M.C., Backes, A.R., 2024. Automated detection of sugarcane crop lines from UAV images using deep learning. *Information Processing in Agriculture* 11 (3), 385–396. <https://doi.org/10.1016/j.inpa.2023.04.001>.

Richardson, A. J., Wiegand, A., 1977. Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing* 43, 1541-1552. https://www.asprs.org/wp-content/uploads/pers/1977journal/dec/1977_dec_1541-1552.pdf.

Salazar-Reque, I., Arteaga, D., Mendoza, F., Rojas, M.E., Soto, J., Huaman, S., Kemper, G., 2023. Differentiating nutritional and water statuses in Hass avocado plantations through a temporal analysis of vegetation indices computed from aerial RGB images. *Computers and Electronics in Agriculture* 213, 108246. <https://doi.org/10.1016/j.compag.2023.108246>.

Sociedade Brasileira da Ciência das Plantas Daninhas (SBCPD). Procedimentos para instalação, avaliação e análise de experimentos com herbicidas. Londrina: SBCPD, 1995. 42 p.

Sow, S., Ranjan, S., Seleiman, M.F., Alkharab Sheh, H.M., Kumar, M., Kumar, N., Padhan, S.R., Roy, D.K., Nath, D., Gitari, H., Wasonga, D.O., 2024. Artificial intelligence for maximizing agricultural input use efficiency: Exploring nutrient, water and weed management strategies. *Phyton-International Journal of Experimental Botany* 93 (7), 1569–1598. <https://doi.org/10.32604/phyton.2024.052241>.

Strehlow, B., De Mol, F., Gerowitt, B., 2020. Herbicide intensity depends on cropping system and weed control target: Unraveling the effects in field experiments. *Crop Protection* 129, 105011. <https://doi.org/10.1016/j.cropro.2019.105011>.

Traxler, C., Gaines, T.A., Küpper, A., Luemmen, P., Dayan, F.E., 2023. The nexus between reactive oxygen species and the mechanism of action of herbicides. *Journal of Biological Chemistry* 299 (11), 105267. <https://doi.org/10.1016/j.jbc.2023.105267>.

Tucker, C.J., 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8 (2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0).

Upadhyay, A., G.C., S., Zhang, Y., Koparan, C., Sun, X., 2024. Development and evaluation of a machine vision and deep learning-based smart sprayer system for site-specific weed management in row crops: An edge computing approach. *Journal of Agriculture and Food Research* 18, 101331. <https://doi.org/10.1016/j.jafr.2024.101331>.

Wei, T., Simko, V., 2021. R package 'corrplot': visualization of a correlation matrix. Version 0.92. <https://github.com/taiyun/corrplot>.

Wickham, H., 2016. *ggplot2: elegant graphics for data analysis*. New York: Springer-Verlag. <https://CRAN.R-project.org/package=ggplot2>.

Woebbecke, D.M., Meyer, G.E., Von Bargen, K., Mortensen, D.A., 1995. Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE* 38 (1), 259–269. <https://doi.org/10.13031/2013.27838>.

Yang, M.-D., Tseng, H.-H., Hsu, Y.-C., Yang, C.-Y., Lai, M.-H., Wu, D.-H., 2021. A UAV open dataset of rice paddies for deep learning practice. *Remote Sensing* 13 (7), 1358. <https://doi.org/10.3390/rs13071358>.

Yang, Z., Willis, P., Mueller, R., 2008. Impact of Band-Ratio Enhanced AWiFS Image to Crop Classification Accuracy. *Proceeding Pecora* 17, 17. <https://api.semanticscholar.org/CorpusID:212788>.

Zaimes, G.N., Gounaridis, D., Symeonakis, E., 2019. Assessing the impact of dams on riparian and deltaic vegetation using remotely-sensed vegetation indices and Random Forests modelling. *Ecological Indicators* 103, 630–641. <https://doi.org/10.1016/j.ecolind.2019.04.047>.

Zakaluk, R., Ranjan, R.S., 2008. Predicting the leaf water potential of potato plants using RGB reflectance. *Canadian Biosystems Engineering* 50, 7.1–7.12.

Zarco-Tejada, P.J., Berjón, A., López-Lozano, R., Miller, J.R., Martín, P., Cachorro, V., González, M.R., De Frutos, A., 2005. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. *Remote Sensing of Environment* 99 (3), 271–287. <https://doi.org/10.1016/j.rse.2005.09.002>.

4.2. Artigo 2 - Análise computacional de imagens de drones na avaliação do controle de plantas daninhas por glyphosate

Artigo elaborado conforme normas da revista *Computers and Electronics in Agriculture*

ANÁLISE COMPUTACIONAL DE IMAGENS DE DRONES NA AVALIAÇÃO DO CONTROLE DE PLANTAS DANINHAS POR GLYPHOSATE

RESUMO

O setor agrícola tem se modernizado, incorporando tecnologias inovadoras para melhorar e otimizar seus processos de produção. Um dos principais desafios da agricultura é o controle de plantas daninhas. Atualmente, a avaliação da eficácia do controle químico é realizada *in loco* por meio de avaliação visual humana, o que pode torná-la ineficiente, imprecisa e demorada. Este estudo tem como objetivo propor modelos gerados por *Random Forest* capazes de avaliar a eficácia do controle de plantas daninhas pelo herbicida glyphosate. As imagens foram obtidas por drone, em quatro diferentes alturas, em uma área com infestação de *Urochloa brizantha*. Para estratificar o controle, aplicou-se as doses de 0, 144, 288, 576, 864, 1152 e 1440 g e.a. ha⁻¹ de glyphosate. Foram utilizados 27 índices de vegetação como variáveis de entrada do modelo, de forma a estimar o controle das plantas daninhas com base nos dados da avaliação visual humana. Os modelos gerados apresentaram valores de r^2 superiores a 90% para todas as alturas de coleta de imagens, tanto nas amostras de treinamento como nas amostras de validação. O elevado desempenho dos modelos nas amostras de validação confirma sua robustez e capacidade de generalização para novos dados. O voo na maior altura testada consumiu quatro vezes menos tempo de voo e gerou um volume de imagens 41,5 vezes menor que a menor altura, o que leva à uma considerável economia no custo geral da avaliação. Este estudo propõe uma solução inovadora e inédita para a avaliação de eficácia do controle de plantas daninhas.

Palavras-chave: índices de vegetação, inteligência artificial, aprendizado de máquina, herbicida.

COMPUTATIONAL ANALYSIS OF DRONE IMAGES IN THE WEED CONTROL EVALUATION USING GLYPHOSATE

ABSTRACT

The agricultural sector has been modernizing, incorporating innovative technologies to improve and optimize its production processes. One of the main challenges in agriculture is the weed control. Currently, the efficacy of chemical control is evaluated on-site via human visual evaluation, which can make it inefficient, inaccurate, and time-consuming. This study aims to propose models generated by Random Forest, capable of evaluating the efficacy of weed control using the herbicide glyphosate. The images were obtained by drone, at four different heights, in an area with *Urochloa brizantha* infestation. To stratify the control, doses of 0, 144, 288, 576, 864, 1152 and 1440 g a.e. ha⁻¹ of glyphosate were applied. Twenty-seven vegetation indices were used as input variables for the model, in order to estimate weed control based on human visual evaluation data. The generated models presented r^2 values greater than 90% at all image collection heights, both in the training and validation samples. The high performance of the models in the validation samples confirms their robustness and ability to generalize to new data. The flight at the highest tested height consumed four times less flight time and generated an image volume 41.5 times smaller than the lowest height, which leads to considerable savings in the overall cost of the evaluation. This study proposes an innovative and novel solution for evaluating the efficacy of weed control.

Keywords: vegetation indices, artificial intelligence, machine learning, herbicide.

Introdução

Assim como diversos setores, a agricultura tem se modernizado e incorporado novas tecnologias para a melhoria e otimização de seus processos de produção. A agricultura de precisão, com o uso de sistemas de posicionamento globais, sensores, câmeras, equipamentos e softwares avançados, possibilita a coleta e análise de dados específicos que permitem uma visão detalhada das condições de interesse do ambiente de forma a proporcionar maior precisão e eficiência na agricultura (Busse *et al.*, 2014; Jensen *et al.*, 2012; Pedersen *et al.*, 2004).

Junto à adoção da agricultura de precisão se destacam os avanços do uso da inteligência artificial (IA) na agricultura moderna, trazendo soluções inovadoras para o setor agrícola. Com o uso de técnicas de aprendizado de máquina, como redes neurais e árvores de decisão, a IA permite o processamento de grande volume de dados para diversos fins, como manejo de doenças (Hu *et al.*, 2024), otimização da irrigação (Preite e Vignali, 2024), e avaliação do estado nutricional e hídrico de plantas (Salazar-Reque *et al.*, 2023).

O uso de IA na agricultura muito frequentemente é aliado ao uso de drones, por serem equipamentos capazes de capturar imagens que podem revelar informações importantes sobre o estado das plantas, solo e entorno, possibilitando a identificação de áreas afetadas por problemas e intervenções mais eficazes e direcionadas (Nazeer *et al.*, 2024; Eladl *et al.*, 2024; Ampatzidis *et al.*, 2020). Quando equipados com câmeras multi e hiperespectrais, esses equipamentos podem capturar informações ainda mais específicas, o que, em geral, proporciona maior precisão (Amarasingam *et al.*, 2024). Entretanto, essas câmeras especiais geralmente são muito caras, o que pode limitar sua adoção para grande parte dos produtores. Neste estudo, optou-se por utilizar apenas câmeras comuns (RGB), que capturam apenas as bandas do visível, a fim de garantir maior acessibilidade e menor custo.

Para lidar com o grande volume de dados dessas imagens, algoritmos de aprendizado de máquina têm sido amplamente utilizados para analisar e obter informações na agricultura (Alaoui *et al.*, 2024; Guduru *et al.*, 2023). Dentre eles, destaca-se o *Random Forest* (RF), conhecido pela sua capacidade de lidar bem com grandes volumes de dados, ter alta eficiência de predição, ser flexível, tolerar bem outliers e ruído, além de ser robusto contra o overfitting, um problema comum em outros algoritmos de IA (Setargie *et al.*, 2023; Aria *et al.*, 2021; Zaimes *et al.*, 2019). O RF é um

algoritmo que trabalha com múltiplas árvores de decisão independentes, capaz de lidar com dados de grandes dimensões e com muitas colinearidades (Belgiu e Drăgu, 2016). Na agricultura, o RF tem sido utilizado com inúmeros objetivos, como estimar a produtividade de culturas e a eficiência do uso de nutrientes (Asamoah *et al.*, 2024), detectar doenças em plantas (Ishengoma e Lyimo, 2024), avaliar a fertilidade do solo (Shahare *et al.*, 2024), estimar indicadores de qualidade de plantas (Polimena *et al.*, 2024) e identificar pontos críticos de risco e fatores de influência de metais pesados em solos agrícolas (Xu *et al.*, 2024).

A agricultura de precisão e o uso da IA têm trazido importantes avanços também na proteção de cultivos contra o ataque de pragas (Mngadi *et al.*, 2024), fitopatógenos (Shubhika *et al.*, 2024) e de plantas daninhas. O manejo de plantas daninhas é um dos principais desafios na agricultura moderna, representando importante parcela dos custos de produção de diferentes sistemas de cultivo. As plantas daninhas competem com as culturas por recursos essenciais, como luz, água e nutrientes, além de causarem outros efeitos negativos não relacionados à competição (Anuch Tiranti *et al.*, 2025; Li e Denich, 2024; Venkataraju *et al.*, 2023). Grande parte da produção agrícola mundial é perdida por causa dessas plantas (Oerke, 2006). O método mais utilizado para o controle de plantas daninhas é o controle químico com herbicidas, sendo o glyphosate a molécula herbicida mais utilizada mundialmente (Benbrook, 2016; Novotny, 2022).

Após a aplicação de um herbicida, é de suma importância que haja a avaliação da eficácia de sua ação. Atualmente, a metodologia mais utilizada para realizar essa avaliação é por meio de avaliações visuais in loco com uso de uma escala de notas que varia de 0 a 100% (Frans, 1972). Entretanto, essa metodologia apresenta problemas como a subjetividade da avaliação humana, a impossibilidade de avaliação precisa de grandes áreas e a dependência total da experiência do avaliador, o que pode tornar a avaliação ineficiente, imprecisa e demorada. Uma possível alternativa a essa metodologia é a utilização de inteligência artificial e índices de vegetação para, a partir de imagens de drone, avaliar-se a eficiência do controle das plantas daninhas pelo herbicida. Nossa hipótese é que essa abordagem permitirá avaliar, com precisão, a eficácia do controle das plantas daninhas por meio das imagens de drone.

Este estudo tem por objetivo propor modelos gerados por *Random Forest* capazes de avaliar a eficácia do controle de plantas daninhas pelo herbicida glyphosate, utilizando índices de vegetação como variáveis de entrada, a partir de imagens capturadas por drone em quatro diferentes alturas.

Materiais e Métodos

Experimento de campo e obtenção de dados de controle e de imagens

No presente estudo, foi utilizada uma área de pouso de cultivo formada com *Urochloa brizantha*, pertencente à Fazenda Experimental do Instituto de Ciências Agrárias da UFMG, na cidade de Montes Claros, estado de Minas Gerais, Brasil (coordenadas geográficas 16° 40' 49,4" S e 43° 50' 20,1" W). O controle das plantas foi realizado com as doses 144, 288, 576, 864, 1152 e 1440 g e.a. ha⁻¹ de glyphosate (Roundup Original Mais®, Monsanto do Brasil, São José dos Campos, Brasil), sendo mantida uma testemunha sem aplicação do herbicida. A área do experimento foi dividida em sete faixas e cada faixa possuía 20 parcelas de 7,5 m² cada (Figura 1). O glyphosate foi aplicado sobre *U. brizantha* quando as plantas atingiram cerca de 40 cm de altura e estavam em boas condições de crescimento vegetativo.

A aplicação das doses de glyphosate foi realizada utilizando um pulverizador costal manual equipado com ponta de pulverização (modelo TTI11002, Teejet, Wheaton, USA) e válvula de pressão constante a 200 kPa (modelo U7466.00, Guarany, Itu, Brasil), calibrado para aplicação de 98,5 L ha⁻¹. As condições ambientais médias no momento da aplicação eram: velocidade do vento de 2,9 km h⁻¹, temperatura de 19,1°C e umidade relativa do ar de 68%.

O controle das plantas foi avaliado visualmente por escala contínua de notas, conforme metodologia proposta por Frans (1972), em que cada parcela recebeu uma nota de controle de 0 a 100% aos 7, 15 e 30 dias após a aplicação do herbicida (DAH). As avaliações visuais de controle foram realizadas por três avaliadores experientes e a nota final para cada parcela determinada pela média aritmética das três observações/avaliadores. Também aos 7, 15 e 30 DAH, com uso de um drone (modelo Phantom 4 Pro, DJI, Shenzhen, China) com sensor de câmera de 20 MP (CMOS 1", DJI, Shenzhen, China), foram obtidas imagens das parcelas tratadas com herbicida. A obtenção das imagens foi realizada em voos aos 20, 40, 80 e 120 metros de altura, a fim de se investigar qual seria a melhor altura para a captura das imagens. O horário dos voos foi padronizado entre 10h da manhã e 12h, para reduzir a influência de sombreamento nas imagens. Durante os voos, as condições de luminosidade foram estáveis, variando entre nublado a parcialmente ensolarado. Os planos de voo foram feitos e conduzidos no software *Map Pilot Pro*. A sobreposição das imagens foi

configurada para 75% de sobreposição lateral e 75% de sobreposição frontal. Para melhorar a precisão da geolocalização da imagem, utilizou-se um sistema de RTK (*Real-Time Kinematic*) (T20, TPS, Nova Lima, Brasil) integrado aos voos do drone. O GSD (*Ground Sample Distance*) representa o menor tamanho de objeto que pode ser distinguido na imagem, com base na altura de voo e nas características do sensor da câmera (Pang *et al.*, 2020; He *et al.*, 2012) e foi calculado a partir da Equação 1. As informações de duração, velocidade média, GSD e número de fotos capturadas em cada voo do drone, de acordo com a altura, estão na Tabela 1.

$$\text{GSD} = \frac{\text{Altura de voo}}{\text{Distância focal}} * \frac{\text{Largura do sensor}}{\text{Largura da imagem}} \quad (1) \quad (\text{Pang } et \text{ al.}, 2020; \text{He } et \text{ al.}, 2012)$$

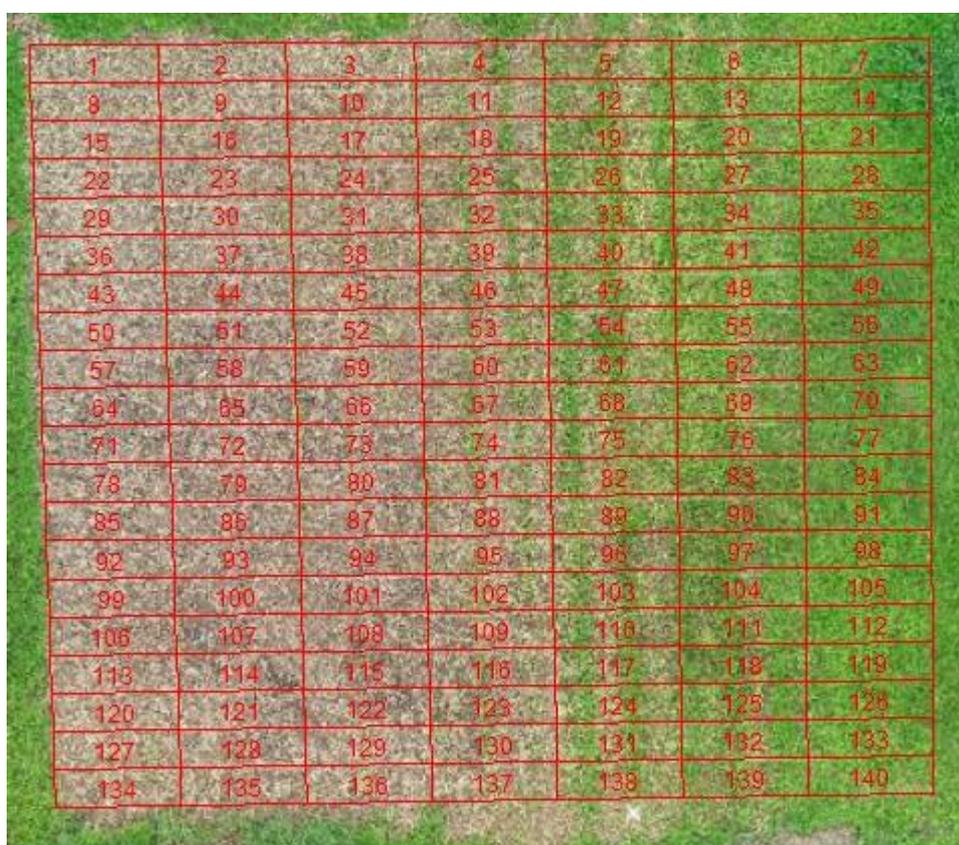


Figura 1. Imagem da área do experimento (ortomosaico) com as marcações das parcelas. Cada coluna representa uma faixa e cada retângulo representa uma parcela.

Tabela 1. Duração, velocidade média, número de imagens geradas e GSD de cada voo do drone de acordo com a altura.

Altura (m)	Tempo de voo (min:s)	Velocidade média de voo (m/s)	Número de fotos capturadas em cada voo	GSD (cm/pixel)
20	11:20	2,5	249	0,532
40	4:17	5,0	73	1,064
80	2:29	10,0	20	2,128
120	2:48	11,0	6	3,192

Após o processamento dessas imagens, foi gerada uma imagem final de cada voo e altura (ortomosaico). A geração dos ortomosaicos foi realizada com o software *Pix4Dmapper*, os pontos de controle (*GCPs*) utilizados apresentaram precisão de 0,020 m.

Análise computacional das imagens

Tratamento e segmentação das imagens

As análises computacionais foram realizadas com o software R (R Core Team, 2024). O pacote *ExplImage* (Azevedo, 2024) foi utilizado para realizar a análise das imagens (Figura 2). Foi obtida uma imagem para cada parcela no campo utilizando-se as funções *ShapeFile_create()* e *ShapeFile_crop()*. Após isso, a imagem de cada parcela foi dividida em quatro, utilizando-se a função *crop_image()*, a fim de ampliar o banco de dados, totalizando 1680 imagens obtidas (20 parcelas x 7 dosagens x 4 replicatas x 3 avaliações) em cada uma das alturas de voo. Das imagens obtidas, 70% delas foram selecionadas aleatoriamente para compor a amostra de treinamento (1176 imagens) e 30% para a amostra de validação (504 imagens). Para a segmentação das imagens, com o objetivo de separar os pixels correspondentes ao solo e às plantas, utilizou-se o índice VARI (Gitelson *et al.*, 2002) e o algoritmo de Otsu (Otsu, 1979) por meio das funções *segmentation()* e *gray_scale()*.

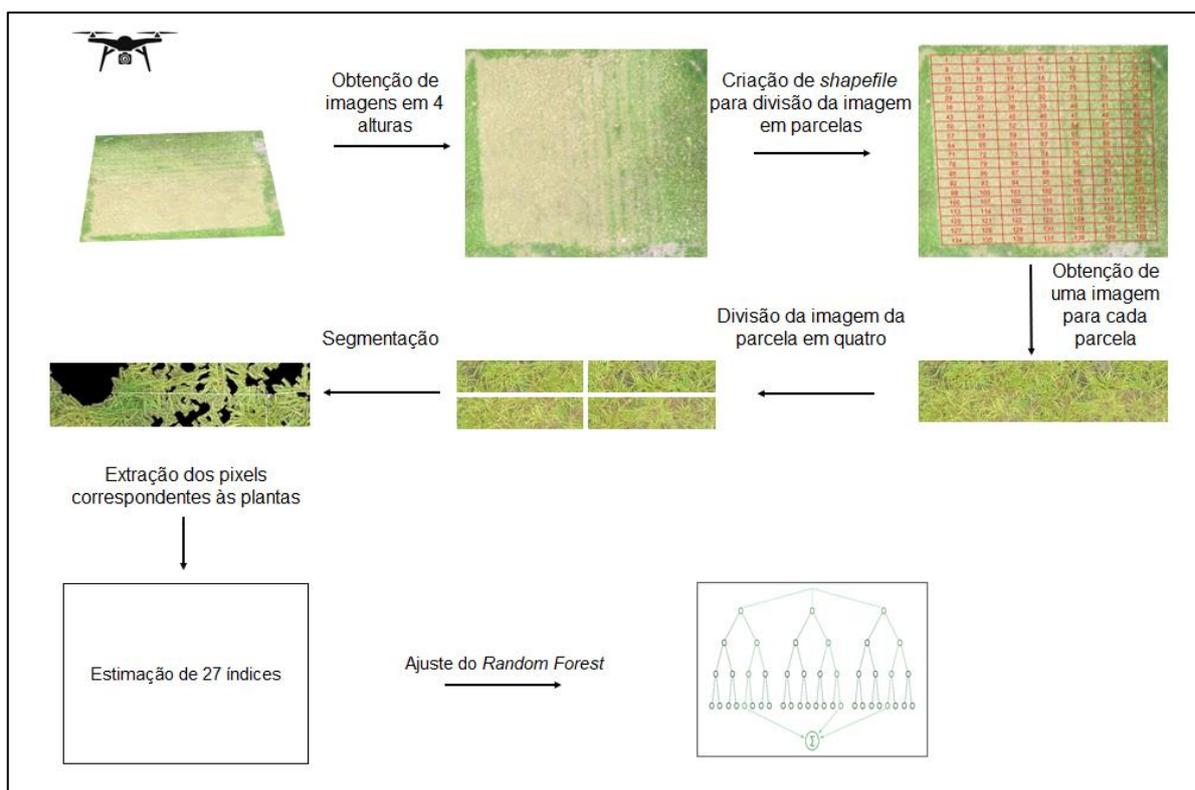


Figura 2. Fluxograma dos passos envolvidos na análise de imagens por *Random Forest* na avaliação do controle de *Urochloa brizantha* com glyphosate.

Obtenção de índices e ajuste dos modelos

Depois da análise e segmentação, estimou-se 27 índices (Tabela 2) com base nos valores dos pixels do *foreground* (correspondentes às plantas). Para cada imagem, os valores dos índices estimados correspondem à média dos valores dos pixels da imagem. Os índices foram obtidos com uso da função *gray_scale()*. Depois disso, foi feita a normalização dos valores dos índices obtidos, com uso da função *normalizeData()* do pacote *RSNNS* (Bergmeir e Benitez, 2012). Isso foi feito para que nenhum índice tivesse maior importância que outro devido apenas à diferença de escalas. As principais funções utilizadas no processamento e os objetivos do seu uso estão na Tabela 3.

Tabela 2. Índices calculados a partir de imagens obtidas por drone na avaliação do controle de *Urochloa brizantha* com glyphosate.

Índices	Nome	Fórmula	Referência
<i>b</i>	<i>Blue</i>	Banda do azul (b)	Azevedo, 2024
<i>b/g</i>	<i>Blue/Green ratio</i>	b/g	Zarco-Tejada <i>et al.</i> , 2005
<i>b/r</i>	<i>Blue/Red ratio</i>	b/r	Zarco-Tejada <i>et al.</i> , 2005
<i>BI</i>	<i>Brightness Index</i>	$\sqrt{(r^2+g^2+b^2)/3}$	Richardson e Wiegand, 1977
<i>BIM</i>	<i>Brightness Index Modified</i>	$\sqrt{(2r+2g+2b)/3}$	Olivoto, 2022
<i>ExG</i>	<i>Excess Green</i>	$(2*g-r-b)$	Woebbecke <i>et al.</i> , 1995
<i>g</i>	<i>Green</i>	Banda do verde (g)	Azevedo, 2024
<i>g/b</i>	<i>Green/Blue ratio</i>	g/b	Zakaluk e Ranjan, 2008
<i>g/r</i>	<i>Green/Red ratio</i>	g/r	Zakaluk e Ranjan, 2008
<i>gb</i>	<i>Mean of green and blue</i>	$(g+b)/2$	Azevedo, 2024
<i>GLI</i>	<i>Green Leaf Index</i>	$(2g-r-b)/(2g+r+b)$	Louhaichi <i>et al.</i> , 2001
<i>HI</i>	<i>Hue Index</i>	$(2r-g-b)/(g-b)$	Escadafal <i>et al.</i> , 1994
<i>HUE</i>	<i>Overall Hue Index</i>	$\text{atan}(2(b-g-r)/30,5(g-r))$	Escadafal <i>et al.</i> , 1994
<i>MGRVI</i>	<i>Modified Green Red Vegetation Index</i>	$(g^2-r^2)/(g^2+r^2)$	Bendig <i>et al.</i> , 2015
<i>MPRI</i>	<i>Modified Photochemical Reflectance Index</i>	$(g-r)/(g+r)$	Yang <i>et al.</i> , 2008
<i>NGRDI</i>	<i>Normalized Green Red Difference Index</i>	$(g-r)/(g+r)$	Tucker, 1979
<i>r</i>	<i>Red</i>	Banda do vermelho (r)	Azevedo, 2024

<i>r/b</i>	<i>Red/Blue ratio</i>	<i>r/b</i>	Zakaluk e Ranjan, 2008
<i>r/g</i>	<i>Red/Green ratio</i>	<i>r/g</i>	Gamon e Surfus, 1999
<i>rb</i>	<i>Mean of red and blue</i>	$(r+b)/2$	Azevedo, 2024
<i>rg</i>	<i>Mean of red and green</i>	$(r+g)/2$	Azevedo, 2024
<i>rgb</i>	<i>Mean of red, green and blue</i>	$(r+g+b)/3$	Olivoto, 2022
<i>RGBVI</i>	<i>Red Green Blue Vegetation Index</i>	$(g^2-b*r)/(g^2+b*r)$	Bendig <i>et al.</i> , 2015
<i>S</i>	<i>S</i>	$((r+g+b)-3b)/(r+g+b)$	Zakaluk e Ranjan, 2008
<i>SCI</i>	<i>Soil Colour Index</i>	$(r-g)/(r+g)$	Mathieu <i>et al.</i> , 1998
<i>SI</i>	<i>Spectral Slope Saturation Index</i>	$(r-b)/(r+b)$	Escadafal <i>et al.</i> , 1994
<i>VARI</i>	<i>Visible Atmospherically Resistant Index</i>	$(g-r)/(g+r-b)$	Gitelson <i>et al.</i> , 2002

Tabela 3. Principais funções utilizadas no R nas fases de tratamento e segmentação das imagens, obtenção de índices e ajuste do modelo.

Funções	Pacote	Objetivo
<i>read_image()</i>	<i>ExplImage</i>	Importação das imagens no R
<i>ShapeFile_create()</i>	<i>ExplImage</i>	Obtenção de uma imagem por parcela
<i>ShapeFile_crop()</i>	<i>ExplImage</i>	Obtenção de uma imagem por parcela
<i>crop_image()</i>	<i>ExplImage</i>	Divisão de cada imagem em quatro
<i>gray_scale()</i>	<i>ExplImage</i>	Segmentação das imagens e obtenção dos índices
<i>segmentation()</i>	<i>ExplImage</i>	Segmentação das imagens

<i>normalizeData()</i>	<i>RNSS</i>	Normalização dos valores dos índices
<i>splitForTrainingAndTest()</i>	<i>randomForest</i>	Divisão dos dados em amostra de treinamento e validação
<i>randomForest()</i>	<i>randomForest</i>	Treinamento do modelo
<i>predict()</i>	<i>randomForest</i>	Avaliação e validação do modelo
<i>importance()</i>	<i>randomForest</i>	Verificação da importância das variáveis

Para o ajuste dos modelos de predição de controle, foi utilizado o método de aprendizado de máquina por árvores de decisão *Random Forest* com uso do pacote *randomForest* (Liaw e Wiener, 2002). Considerou-se os 27 índices estimados como as variáveis de entrada para o algoritmo. Os modelos foram treinados para realizar a predição da nota de controle, ajustando-se aos dados das notas de controle atribuídas pelos três avaliadores. Foi ajustado um modelo para cada uma das quatro alturas de voo e, posteriormente, foi ajustado um modelo considerando todas as imagens, independentemente da altura, com o objetivo de verificar a possibilidade de que um único modelo fosse útil sem depender da altura de voo. Devido à aleatoriedade inerente aos algoritmos de inteligência artificial, a cada execução os valores estimados mudavam ligeiramente. Por isso, a fim de melhorar a precisão, a robustez e a generalização do modelo, foi usado o método ensemble. Logo, foram ajustados 100 modelos de RF e, posteriormente, considerou-se a média da variável de saída correspondente a cada imagem.

Análise estatística

As análises estatísticas deste estudo foram realizadas com o auxílio do software R (R Core Team, 2024). A associação existente entre os índices foi avaliada por meio da estimação da correlação de Pearson entre eles com uso do pacote *stats* (R Core Team, 2024). Essas correlações foram apresentadas em forma de uma matriz de correlação, gerada utilizando-se o pacote *corrplot* (Wei e Simko, 2021). A associação entre os valores de cada índice e os valores das notas visuais foi analisada com a

estimação da correlação de Pearson e do coeficiente de determinação para cada correlação, apresentados em gráficos de barras gerados com uso do pacote *ggplot2* (Wickham, 2016).

Utilizou-se o coeficiente de determinação obtido da regressão linear entre os valores observados (notas visuais atribuídas pelos avaliadores) e os valores preditos (estimados pelo modelo) para verificar a eficiência dos modelos de *Random Forest* ajustados. Esses dados foram apresentados por meio de gráficos de dispersão gerados com o pacote *ggplot2* (Wickham, 2016).

A importância de cada um dos índices para o ajuste do modelo foi dada pela função *importance()* do pacote *randomForest* (Liaw e Wiener, 2002). Essas estimativas foram apresentadas em gráficos de barra, sendo que os valores de importância apresentados correspondem à importância média desses índices obtidos nas 100 execuções, acompanhados por uma barra que representa o intervalo de confiança (95%), calculado a partir do teste t.

Para analisar a robustez dos modelos ao *overfitting*, foi avaliado o desempenho preditivo dos modelos com os dados de validação, quanto maior seu desempenho, maior sua robustez. O *overfitting* ocorre quando o algoritmo se prende a aspectos irrelevantes dos dados de treinamento e perde sua capacidade de generalização e aplicação em novos dados (Bramer, 2013), por isso, um alto desempenho com dados não vistos no treinamento indica boa capacidade de generalização.

Resultados

Índices de vegetação que utilizaram combinações de bandas de forma similar, em geral, apresentaram alta correlação positiva entre si (Figura 3), como o caso dos pares NGRDI e g/r (ambos buscaram destacar a banda do verde e atenuar a banda do vermelho) e BI e rgb (ambos buscaram capturar médias globais de cor, não focando em uma banda específica). Enquanto isso, índices que utilizaram combinações de bandas com objetivos opostos apresentaram correlação negativa entre si, como os pares VARI e r/g (o primeiro buscou destacar o efeito da banda do verde e o segundo buscou diminuí-lo) e b/g e ExG (o primeiro tem por objetivo destacar a banda do azul em detrimento da banda do verde enquanto o segundo busca o contrário, destacar a banda do verde em detrimento das outras bandas) (Figura 3).

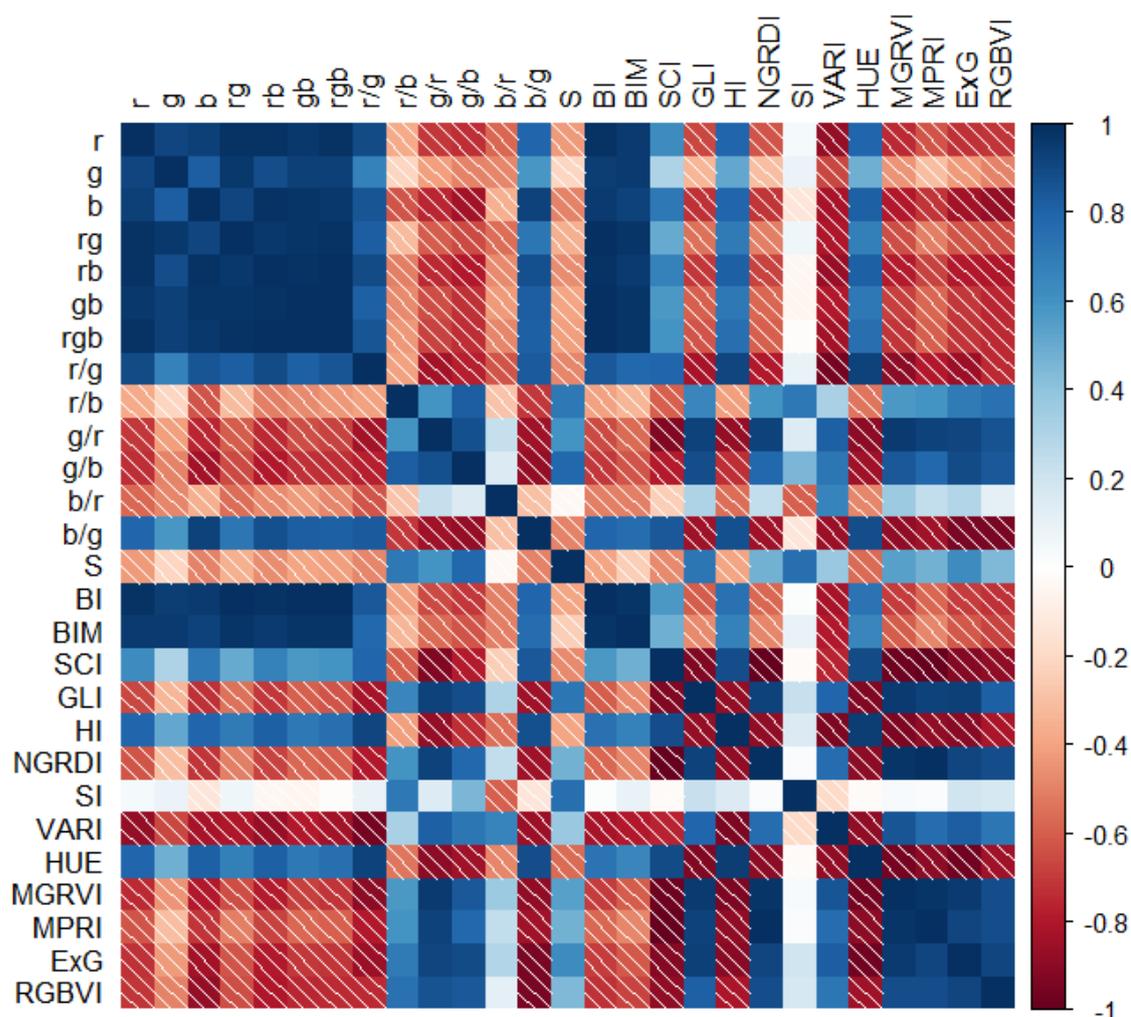


Figura 3. Estimativas da correlação de Pearson entre índices de vegetação obtidos com uso de imagens de drone, a partir dos dados de todas as alturas, para a avaliação do controle de plantas daninhas com glyphosate em *Urochloa brizantha*.

As correlações de Pearson entre as notas visuais de controle e os índices de vegetação estimados, de acordo com a altura de voo, são apresentadas na Figura 4. A variação na altura de voo influenciou a correlação dos índices com as notas visuais, entretanto, observando-se os cinco primeiros índices com maior valor de correlação em cada altura, alguns índices se repetiram pelo menos duas vezes, sendo dos índices que apresentaram correlação linear diretamente proporcional com as notas visuais: HI, rb, HUE, r/g, SCI e b (com valores de correlação entre 0,91 e 0,84), e dos índices que apresentaram correlação linear inversamente proporcional: GLI, MGRVI, VARI, ExG, NGRDI e g/b, que apresentaram correlação com as notas entre 0,91 e 0,69 (Figura 4).

Também observou-se uma queda nos valores gerais de correlação dos índices com o aumento da altura, observando-se uma queda mais acentuada dos índices com

correlação inversamente proporcional com as notas visuais e uma queda menos acentuada dos índices com correlação positiva com as notas (Figura 4).

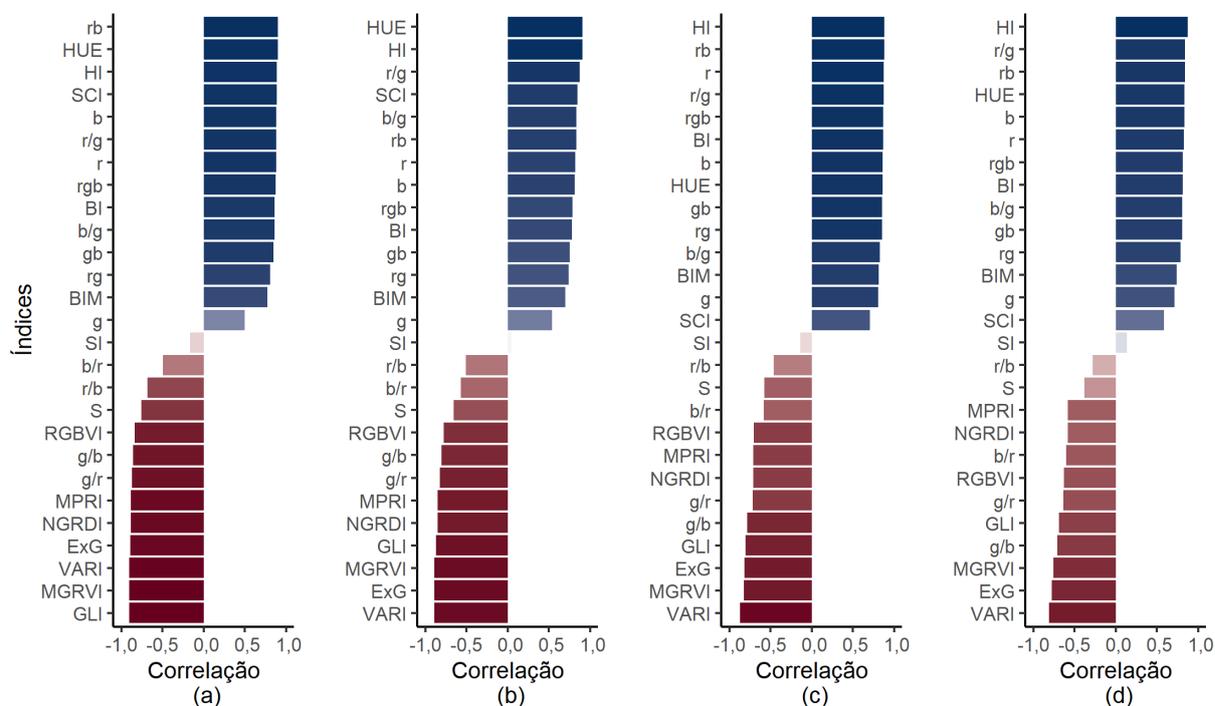


Figura 4. Estimativas da correlação de Pearson no estudo da associação entre notas visuais de controle e os índices de vegetação estimados em imagens obtidas por drone na altura de 20 (a), 40 (b), 80 (c) e 120 m (d) na avaliação do controle de *Urochloa brizantha* por glyphosate.

Considerando-se os cinco primeiros índices com maior valor do coeficiente de determinação r^2 em cada altura, os índices que se repetiram pelo menos duas vezes foram o VARI, rb, HUE, HI, MGRVI e r/g, apresentando coeficientes de determinação entre 80 e 70% (Figura 5). Por outro lado, entre os cinco primeiros índices com menor valor de r^2 , os índices repetidos pelo menos duas vezes (com exceção do índice SI, que apresentou r^2 próximo de zero) foram os índices S, r/b, b/r, g, BIM e SCI, com r^2 entre 8 e 60%.

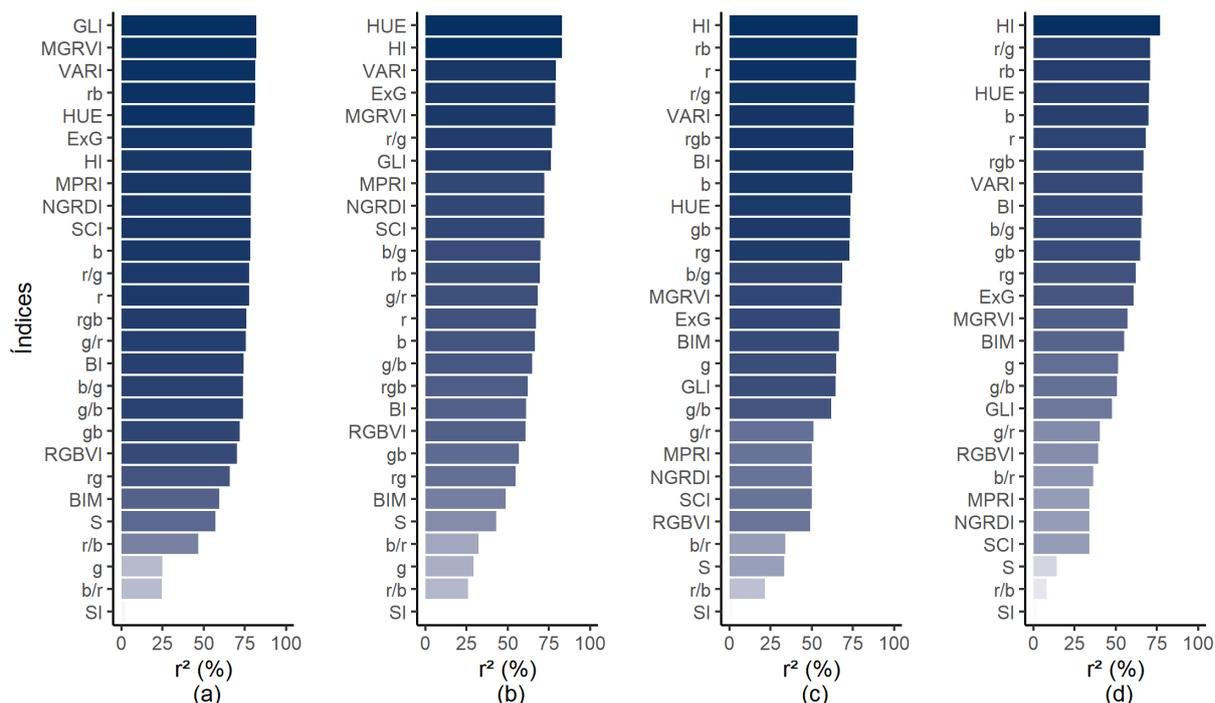


Figura 5. Estimativas do coeficiente de determinação considerando o modelo de regressão linear no estudo da associação entre notas visuais de controle e os índices de vegetação estimados em imagens obtidas por drone nas alturas de 20 (a), 40 (b), 80 (c) e 120 m (d) na avaliação do controle de *Urochloa brizantha* por glyphosate.

As regressões lineares apresentadas na Figura 6, realizadas para avaliar a qualidade do ajuste do *Random Forest* (RF), mostraram alta precisão dos modelos gerados (r^2 maior que 90% para as amostras de treinamento e de validação) na previsão das notas visuais de controle de *U. brizantha* por glyphosate com uso dos índices de vegetação como variáveis de entrada. O RF conseguiu lidar bem com as diferenças dos dados decorrentes da altura (variação da qualidade das imagens e quantidade de dados disponíveis, por variação na resolução e consequente variação na quantidade de pixels) e manteve boa precisão, mesmo na maior altura, apresentando r^2 de 90,20% para a amostra de treinamento e 90,84% para a amostra de validação (Figuras 6g e 6h).

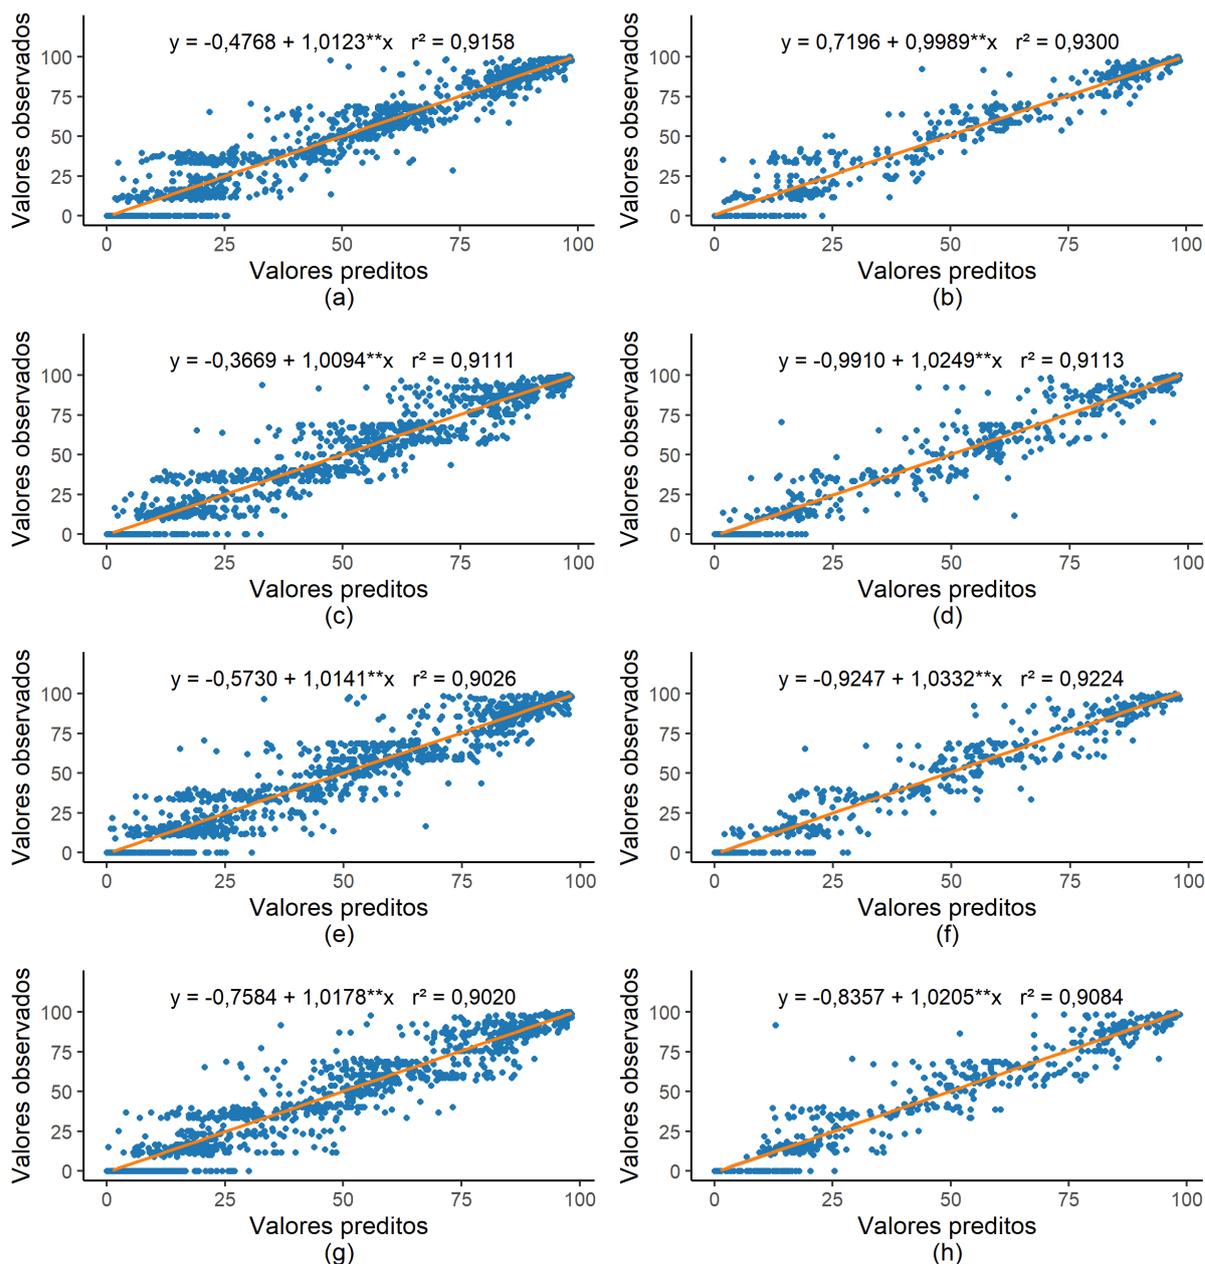


Figura 6. Avaliação da qualidade do ajuste do *Random Forest* na estimação das notas associadas à avaliação do controle de *Urochloa brizantha* por glyphosate a partir de imagens de drone nas alturas de 20 (a, b), 40 (c, d), 80 (e, f) e 120 m (g, h) para a amostra de treinamento (a, c, e, g) e validação (b, d, f, h).

Os índices de vegetação GLI, r/g, HI e HI foram os de maior importância para o treinamento dos modelos nas alturas de 20, 40, 80 e 120 m, respectivamente (Figura 7).

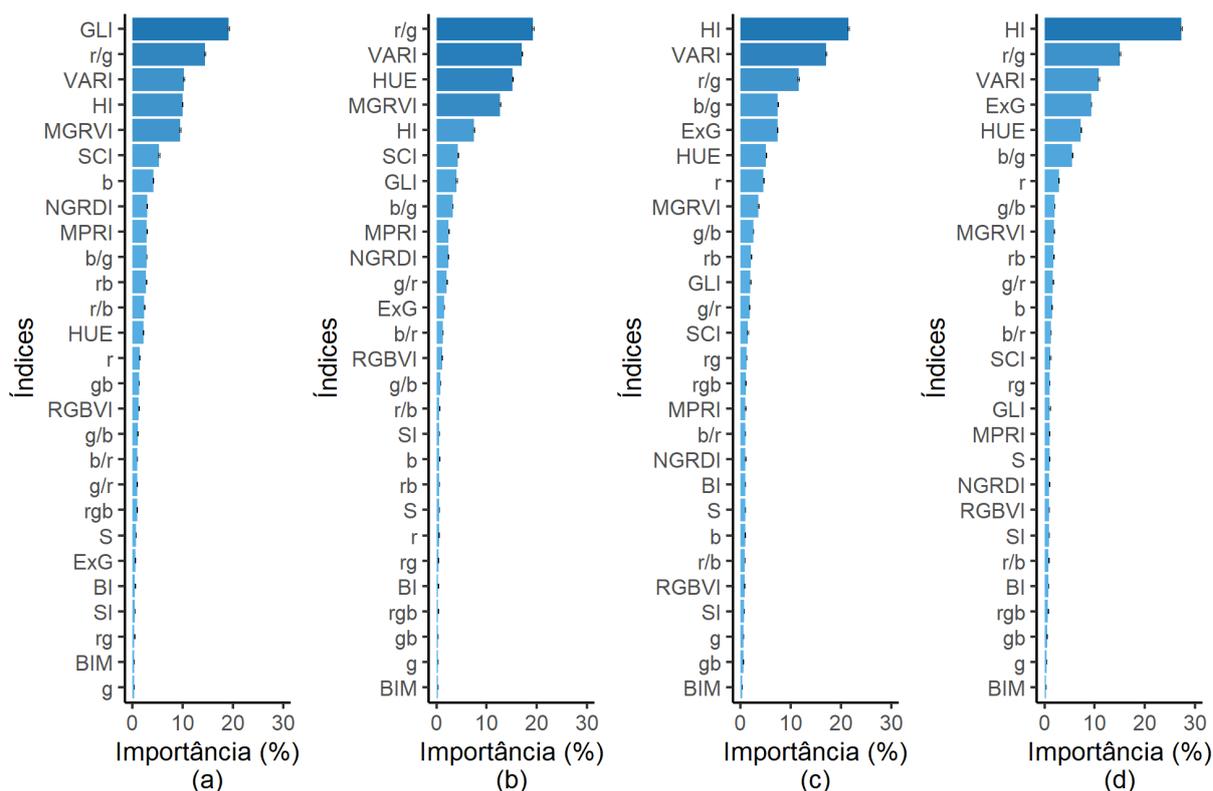


Figura 7. Importância dos índices de vegetação no ajuste do *Random Forest* com barras representando o intervalo de confiança da média a 5% de significância pelo teste t na estimação das notas visuais de controle de *Urochloa brizantha* por glyphosate a partir de imagens obtidas por drone nas alturas de 20 (a), 40 (b), 80 (c) e 120 m (d).

Ajuste do modelo de predição de notas de controle independente da altura de voo

A análise das correlações de Pearson e dos coeficientes de determinação, considerando as regressões lineares das associações entre as notas de controle e os índices de vegetação, independente da altura, são apresentadas na Figura 8. Para as correlações de Pearson, observou-se que os índices que apresentaram correlações diretamente proporcionais com as notas variaram entre 0,87 (HUE) e 0,61 (g) e os que apresentaram correlações inversamente proporcionais variaram entre 0,85 (VARI) e 0,74 (RGBVI), como mostrado na Figura 8a. Os índices r/b, S e b/r também apresentaram correlações negativas entre 0,45 e 0,53 (Figura 8a). O índice SI apresentou correlação próxima de zero com as notas (Figura 8a).

Observa-se que os índices que apresentaram maiores valores de r^2 das associações foram: HUE, HI, r/g, VARI, rb, ExG e MGRVI, com valores de coeficiente de determinação entre 76 e 70% (Figura 8b). Os índices b, r, b/g, GLI, rgb, BI e gb

apresentaram valores de r^2 entre 60 e 69% (Figura 8b). Todos os demais índices apresentaram r^2 menores que 60% (Figura 8b).

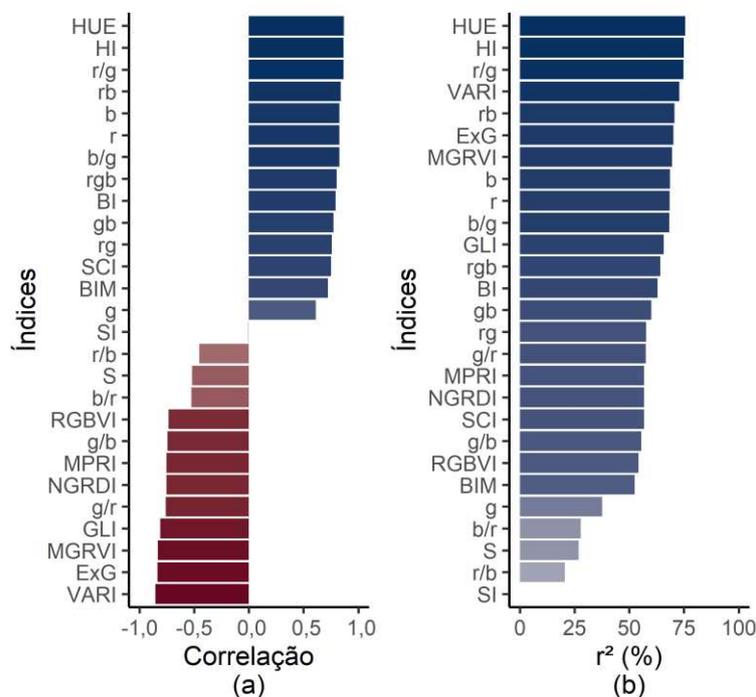


Figura 8. Estimativas do coeficiente de correlação (a) e do coeficiente de determinação (b), considerando o modelo de regressão linear, no estudo da associação entre notas visuais de controle e os índices de vegetação estimados em imagens obtidas por drone, independente da altura, na avaliação do controle de *Urochloa brizantha* por glyphosate.

O modelo treinado para prever as notas de controle, independente da altura, apresentou r^2 do ajuste entre os valores preditos e observados no treinamento de 91,33% (Figura 9a) e r^2 de 90,91% entre os valores preditos e observados na validação (Figura 9b), mostrando a alta capacidade do modelo em explicar as variações na variável dependente (notas visuais de controle) com uso dos índices de vegetação calculados, independentemente da altura de voo (Figura 9).

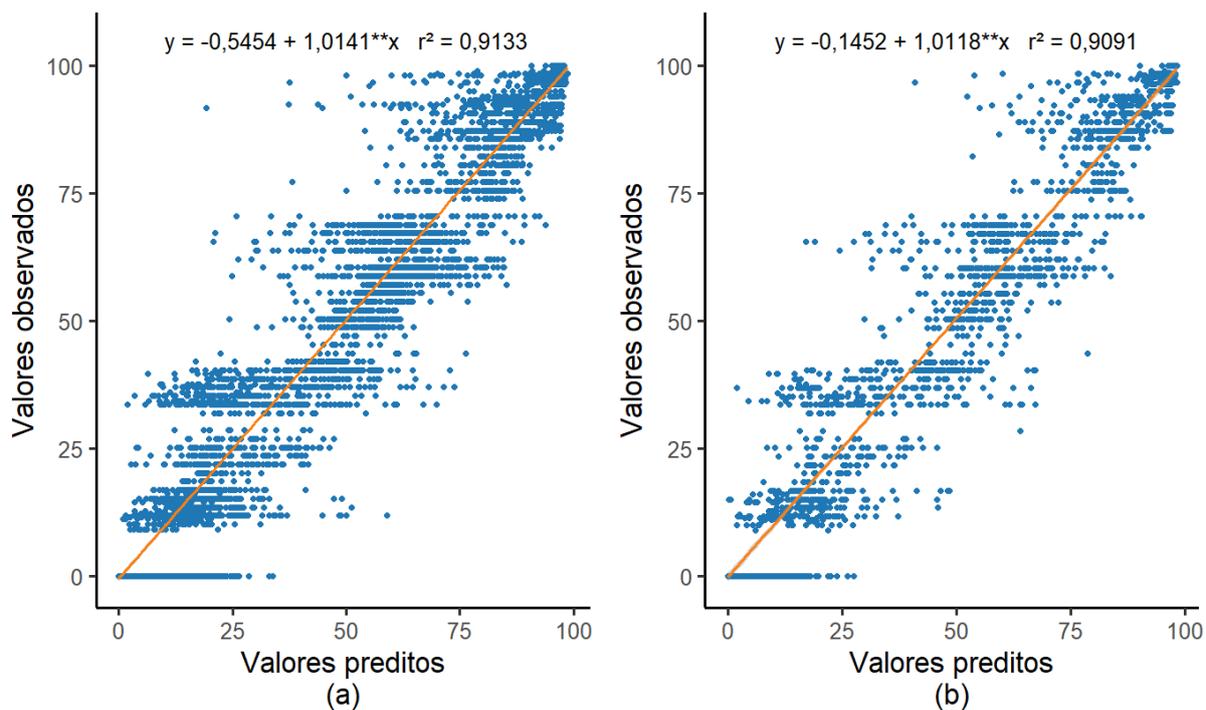


Figura 9. Avaliação da qualidade do ajuste do *Random Forest* na estimação das notas associadas à avaliação do controle de *Urochloa brizantha* por glyphosate a partir de imagens de drone, independente da altura, para a amostra de treinamento (a) e validação (b).

Os índices mais importantes para o ajuste desse modelo foram o HI, o r/g e o VARI, apresentando mais de 15% de importância cada (Figura 10).

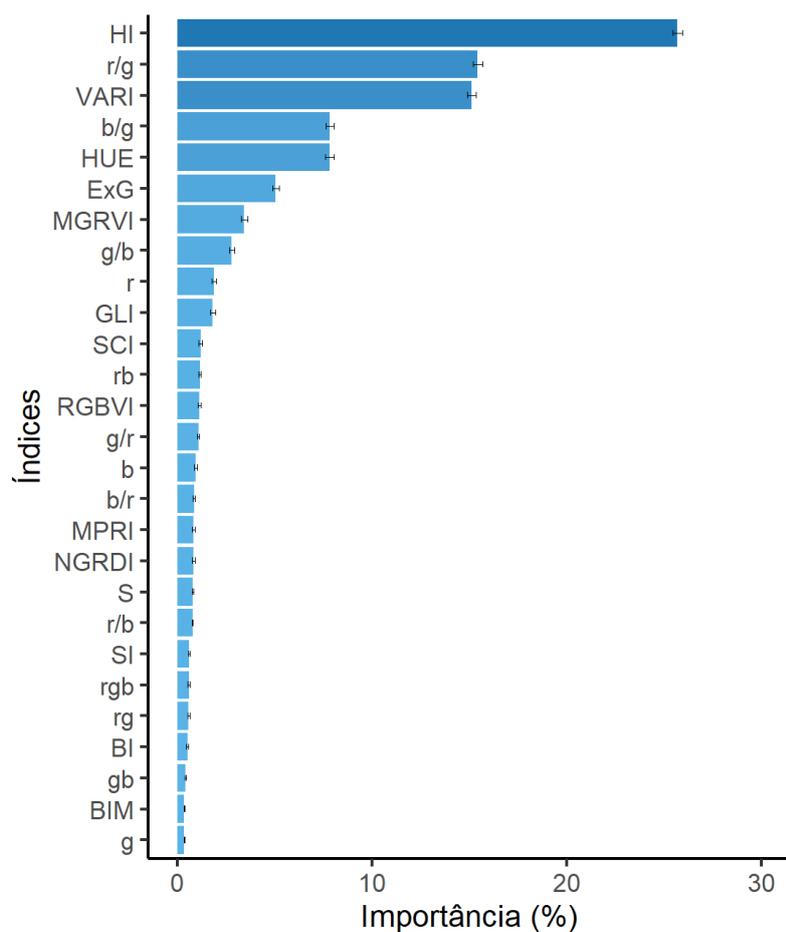


Figura 10. Importância dos índices no ajuste do *Random Forest* com barras representando o intervalo de confiança da média a 5% de significância pelo teste t na estimação das notas visuais de controle de *Urochloa brizantha* por glyphosate a partir de imagens obtidas por drone, independente da altura de voo.

Discussão

Os modelos gerados por *Random Forest* (RF) foram altamente eficazes ($r^2 > 0,90$) na avaliação da eficácia do controle das plantas daninhas pelo glyphosate, independentemente da altura de voo do drone testada (Figura 6). Além disso, o modelo gerado independente da altura (Figura 9) mostrou alta precisão nas predições das notas ($r^2 > 90\%$), o que permite dizer que o modelo pode ser usado em condições mais amplas, em situações nas quais os dados variem em termos de altura e/ou qualidade da imagem, dentro da faixa de 20 a 120 m de altura de voo.

A alta eficiência dos modelos gerados com as imagens capturadas em maiores alturas, como conseguido no presente estudo com 120 metros de altura, permite economia da bateria do equipamento e maior rendimento do voo/área avaliada. O voo na maior altura testada (120 metros) consumiu quatro vezes menos tempo de voo e gerou um volume de imagens 41,5 vezes menor que a altura de 20 metros (Tabela 1), o que resulta em menor gasto com mão de obra, menor desgaste do equipamento, menor capacidade exigida de armazenamento e redução considerável no tempo de processamento computacional das imagens, levando a uma economia no custo geral da avaliação, principalmente em áreas maiores.

Os modelos gerados se mostraram robustos contra o *overfitting*, como pode ser observado pelo bom desempenho dos modelos ($r^2 > 90\%$) nas amostras de validação (Figura 6). A robustez dos modelos contra esse problema é de suma relevância para sua aplicação em novos dados, tendo em vista que o *overfitting* causa a perda da capacidade de generalização do modelo para aplicação em dados diferentes dos vistos no treinamento (Bramer, 2013).

A matriz de correlação entre índices (Figura 3) permitiu observar que índices que relacionaram bandas de forma parecida tiveram alta correlação positiva entre si e, quando relacionaram bandas de forma inversa, tenderam a apresentar alta correlação negativa entre si. Com isso, é possível selecionar índices redundantes e otimizar o processo de modelagem. Além disso, caso o cálculo de algum índice não seja possível, ele pode ser substituído por um índice de comportamento igual ou similar (Figura 3).

Os gráficos de importância (Figuras 7 e 10) são importantes para a avaliação de quais índices foram mais relevantes para o treinamento dos modelos, isto é, quais índices foram mais úteis para prever as notas de controle, o que permite escolher os melhores índices para avaliação e diminuir o esforço computacional para a geração dos

índices e, conseqüentemente, dos modelos de predição. De acordo com os gráficos com os coeficientes de determinação das regressões lineares entre os índices de vegetação e as notas visuais de controle (Figura 5), é possível notar que a maioria dos índices tiveram alta correlação com as notas visuais, o que é muito útil para a eficiência do modelo (Ramos *et al.*, 2020).

Este estudo traz resultados inéditos, mostrando o sucesso da avaliação da eficácia de controle de plantas daninhas com glyphosate por meio de imagens classificadas por *Random Forest*. Embora diversos estudos tenham utilizado drones e *Random Forest* nas ciências agrárias para fins variados, como avanços nos sistemas de controle de pulverização (Wang *et al.*, 2024), estimativa de salinidade do solo (Tan *et al.*, 2024), quantificação de clorofila nas folhas (Priyanka *et al.*, 2023), detecção de déficit hídrico em plantas (Ma *et al.*, 2024) e estimativa de nitrogênio na planta (Peng *et al.*, 2021), não foram encontrados pelos autores deste estudo nenhum artigo que usasse esses recursos para a avaliação da eficiência do controle de plantas daninhas.

É importante dizer que a precisão dos modelos gerados depende diretamente do sucesso da segmentação das imagens, neste estudo realizada pelo método de Otsu (Otsu, 1979). Portanto, se as imagens não forem devidamente segmentadas, extraindo-se os pixels de interesse, no caso, as plantas, o algoritmo poderia enfrentar problemas para realizar as predições das notas, já que os índices de cor calculados também se refeririam a objetos de não interesse, comprometendo a precisão do modelo.

Os resultados deste estudo mostram que o uso do RF, aliado aos índices de vegetação, é muito útil para a avaliação do controle de plantas daninhas com uso de imagens capturadas por drones, sendo possível o uso de altitudes maiores, dentro da faixa de 20 a 120 metros testada, que possibilitam aliar tecnologia a um menor custo operacional (mão de obra e tempo de uso dos equipamentos de voo) e muito menor esforço computacional quando comparadas às menores altitudes testadas. Além disso, o modelo gerado independente da altura possibilita o uso de dados de diferentes alturas para treinamento do modelo, trazendo vantagens significativas para o processo de modelagem.

Outra vantagem do método proposto para a avaliação de controle de plantas daninhas com uso de imagens e RF é que, em tese, os modelos gerados também podem ser usados para a avaliação de controle de outras plantas, considerando que os modelos foram treinados com índices de cor como variáveis de entrada, isto é, usados para calcular a variação de cor da planta e que qualquer planta apresentará variação de cor

durante a ação dos herbicidas, como perda da cor verde (típico de plantas saudáveis) para uma coloração mais próxima do marrom ou cinza (típica de uma planta morta). Semelhantemente, espera-se que os modelos possam ser aplicados para a avaliação de controle também por diferentes herbicidas, considerando que a maioria dos herbicidas causam alterações semelhantes na cor das plantas durante sua ação, como o atrazine (Traxler *et al.*, 2023), o glyphosate (Ferreira *et al.*, 2023), o dicamba e o glufosinato de amônio (Ghimire *et al.*, 2023) e o 2,4 D (Brochado *et al.*, 2022).

O uso de uma câmera comum, que capta apenas as bandas do visível (RGB) e um drone popular (Phantom 4) contrasta positivamente com a alta performance dos modelos, o que resultou em uma avaliação muito mais acessível economicamente do que se tivesse feito o uso de câmeras especiais, como as multi (Yang *et al.*, 2025) e hiperespectrais (Zhou *et al.*, 2025), geralmente com preços elevados e inacessíveis para grande parte dos produtores.

Conclusões

Os modelos gerados por *Random Forest* são capazes de avaliar com sucesso a eficácia do controle de plantas daninhas, alcançando precisão superior a 90% tanto nas amostras de treinamento como nas amostras de validação, independentemente da altura de voo.

Os modelos são robustos contra o *overfitting*, possibilitando seu uso e aplicação em novos dados. O uso dos índices de vegetação como variáveis de entrada é assertivo e sua utilização no treinamento é fundamental para o sucesso da modelagem.

O modelo gerado independente da altura de voo apresenta alta precisão de predição das notas de controle ($r^2 > 90\%$), mostrando que o modelo pode ser aplicado em condições nas quais os dados variem em termos de altura e/ou em qualidade da imagem, desde que dentro da faixa de altura de voo testada (20 a 120 metros).

REFERÊNCIAS

Alaoui, M.E., Amraoui, K.E., Masmoudi, L., Ettouhami, A., Rouchdi, M., 2024. Unleashing the potential of IoT, Artificial Intelligence, and UAVs in contemporary agriculture: A comprehensive review. *Journal of Terramechanics* 115, 100986. <https://doi.org/10.1016/j.jterra.2024.100986>.

Amarasingam, N., Kelly, J.E., Sandino, J., Hamilton, M., Gonzalez, F., Dehaan, R.L., Zheng, L., Cherry, H., 2024. Bitou bush detection and mapping using UAV-based multispectral and hyperspectral imagery and artificial intelligence. *Remote Sensing Applications: Society and Environment* 34, 101151. <https://doi.org/10.1016/j.rsase.2024.101151>.

Ampatzidis, Y., Partel, V., Costa, L., 2020. Agroview: Cloud-based application to process, analyze and visualize UAV-collected data for precision agriculture applications utilizing artificial intelligence. *Computers and Electronics in Agriculture* 174, 105457. <https://doi.org/10.1016/j.compag.2020.105457>.

Anuch Tiranti, J.V., Curti, R.N., Acreche, M.M., 2025. Competitiveness of chia against brassica weeds improves through a narrow spatial arrangement. *Crop Protection* 187, 106973. <https://doi.org/10.1016/j.cropro.2024.106973>.

Aria, M., Cuccurullo, C., Gnasso, A., 2021. A comparison among interpretative proposals for Random Forests. *Machine Learning with Applications* 6, 100094. <https://doi.org/10.1016/j.mlwa.2021.100094>.

Asamoah, E., Heuvelink, G.B.M., Chairi, I., Bindraban, P.S., Logah, V., 2024. Random forest machine learning for maize yield and agronomic efficiency prediction in Ghana. *Heliyon* 10 (17), e37065. <https://doi.org/10.1016/j.heliyon.2024.e37065>.

Azevedo, A.M., 2024. ExplImage: Analysis of Images in Experiments. Cran-R. <https://cran.r-project.org/package=ExplImage>.

Belgiu, M., Drăguț, L., 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing* 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.

Benbrook, C.M., 2016. Trends in glyphosate herbicide use in the United States and globally. *Environmental Sciences Europe* 28 (1), 3. <https://doi.org/10.1186/s12302-016-0070-0>.

Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M.L., Bareth, G., 2015. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation* 39, 79–87. <https://doi.org/10.1016/j.jag.2015.02.012>.

Bergmeir, C., Benitez, J.M., 2012. Neural networks in R using the Stuttgart neural network simulator: RSNNS. *Journal of Statistical Software* 46 (7), 1–26. <https://cran.r-project.org/package=RSNNS>.

Bramer, M., 2013. Avoiding overfitting of decision trees. In: BRAMER, M. Principles of data mining. Undergraduate topics in computer science. London: Springer, 121–136. https://doi.org/10.1007/978-1-4471-4884-5_9.

Brochado, M.G.D.S., Mielke, K.C., Paula, D.F.D., Laube, A.F.S., Alcántara-de La Cruz, R., Gonzatto, M.P., Mendes, K.F., 2022. Impacts of dicamba and 2,4-D drift on 'Ponkan' mandarin seedlings, soil microbiota and *Amaranthus retroflexus*. *Journal of Hazardous Materials Advances* 6, 100084. <https://doi.org/10.1016/j.hazadv.2022.100084>.

Busse, M., Doernberg, A., Siebert, R., Kuntosch, A., Schwerdtner, W., König, B., Bokelmann, W., 2014. Innovation mechanisms in German precision farming. *Precision Agriculture* 15, 403–426. <https://doi.org/10.1007/s11119-013-9337-2>.

Eladl, S.G., Haikal, A.Y., Saafan, M.M., Zaineldin, H.Y., 2024. A proposed plant classification framework for smart agricultural applications using UAV images and artificial intelligence techniques. *Alexandria Engineering Journal* 109, 466–481. <https://doi.org/10.1016/j.aej.2024.08.076>.

Escadafal, R., Belghit, A., Ben-Moussa, H., 1994. Indices spectraux pour la télédétection de la dégradation des milieux naturels en Tunisie aride. In: Actes du 6ème Symposium international sur les mesures physiques et signatures en télédétection, Val d'Isère (France), pp. 253–259.

Ferreira, M.F., Torres, C., Bracamonte, E., Galetto, L., 2023. Glyphosate affects the susceptibility of non-target native plant species according to their stage of development and degree of exposure in the landscape. *Science of The Total Environment* 865, 161091. <https://doi.org/10.1016/j.scitotenv.2022.161091>.

Frans, R.W., 1972. Measuring plants response. In: WILKINSON, R.E. (Ed.). *Research methods in weed science*. Puerto Rico: Weed Science Society, 28–41.

Gamon, J.A., Surfus, J.S., 1999. Assessing leaf pigment content and activity with a reflectometer. *New Phytologist* 143, 105–117. <https://doi.org/10.1046/j.1469-8137.1999.00424.x>.

Ghimire, B.K., Yu, C.Y., Kim, S.H., Chung, I.M., 2023. Evaluation of pre-emergence and post-emergence herbicides for weed management in *Miscanthus sacchariflorus* and *Miscanthus sinensis*. *Phyton-International Journal of Experimental Botany* 92 (5), 1439–1467. <https://doi.org/10.32604/phyton.2023.023076>.

Gitelson, A.A., Kaufman, Y.J., Stark, R., Rundquist, D., 2002. Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment* 80 (1), 76–87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9).

Guduru, D., Khatri, N., Kumar, S., Shukla, P. K., 2023. A comprehensive review of machine vision systems and artificial intelligence algorithms for the detection and harvesting of agricultural produce. *Scientific African* 21, e01798. <https://doi.org/10.1016/j.sciaf.2023.e01798>.

He, J., Li, Y., Zhang, K., 2012. Research of UAV Flight Planning Parameters. *Positioning* 3 (4), 43–45. <https://doi.org/10.4236/pos.2012.34006>.

- Hu, Y., Tang, J., Yang, J., 2024. Introducing artificial intelligence technology to plant disease management for sustainable agriculture. *Crop Protection* 184, 106764. <https://doi.org/10.1016/j.cropro.2024.106764>.
- Ishengoma, F.S., Lyimo, N.N., 2024. Ensemble model for grape leaf disease detection using CNN feature extractors and random forest classifier. *Heliyon* 10 (12), e33377. <https://doi.org/10.1016/j.heliyon.2024.e33377>.
- Jensen, H.G., Jacobsen, L.-B., Pedersen, S.M., Tavella, E., 2012. Socioeconomic impact of widespread adoption of precision farming and controlled traffic systems in Denmark. *Precision Agriculture* 13, 661–677. <https://doi.org/10.1007/s11119-012-9276-3>.
- Li, L., Denich, M., 2024. Niche and interspecific relationship of alligator weed (*Alternanthera philoxeroides*) after a hundred years' invasion in central China. *Heliyon* 10 (20), e39064. <https://doi.org/10.1016/j.heliyon.2024.e39064>.
- Liaw, A., Wiener, M., 2002. Classification and regression by randomForest. *R News* 2 (3), 18–22. <https://CRAN.R-project.org/doc/Rnews/>.
- Louhaichi, M., Borman, M.M., Johnson, D.E., 2001. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International* 16 (1), 65–70. <https://doi.org/10.1080/10106040108542184>.
- Ma, X., Zhang, F., Luo, H., Guo, G., 2024. Water shortage detection of jujube trees based on spectral technology and random forest classifier integrated with fractal theory. *Industrial Crops and Products* 216, 118729. <https://doi.org/10.1016/j.indcrop.2024.118729>.
- Mathieu, R., Pouget, M., Cervelle, B., Escadafal, R., 1998. Relationships between satellite-based radiometric indices simulated using laboratory reflectance data and typical soil color of an arid environment. *Remote Sensing of Environment* 66 (1), 17–28. [https://doi.org/10.1016/S0034-4257\(98\)00030-3](https://doi.org/10.1016/S0034-4257(98)00030-3).
- Mngadi, M., Germishuizen, I., Mutanga, O., Naicker, R., Maes, W.H., Odebiri, O., Schroder, M., 2024. A systematic review of the application of remote sensing technologies in mapping forest insect pests and diseases at a tree-level. *Remote Sensing Applications: Society and Environment* 36, 101341. <https://doi.org/10.1016/j.rsase.2024.101341>.
- Nazeer, I., Umer, S., Rout, R. K., Tanveer, M., 2024. Artificial intelligence-based smart agricultural systems for saffron cultivation with integration of Unmanned Aerial Vehicle imagery and deep learning approaches. *Computers and Electrical Engineering* 119, 109542. <https://doi.org/10.1016/j.compeleceng.2024.109542>.
- Novotny, E., 2022. Glyphosate, Roundup and the Failures of Regulatory Assessment. *Toxics* 10 (6), 321. <https://doi.org/10.3390/toxics10060321>.
- Oerke, E.-C., 2006. Crop losses to pests. *The Journal of Agricultural Science* 144 (1), 31–43. <https://doi.org/10.1017/S0021859605005708>.
- Olivoto T., 2022. Lights, camera, pliman! An R package for plant image analysis. *Methods Ecol. Evol.* 13 (4), 789–798.

Otsu, N., 1979. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics* 9 (1), 62–66.

Pang, Y., Shi, Y., Gao, S., Jiang, F., Veeranampalayam-Sivakumar, A.-N., Thompson, L., Luck, J., Liu, C., 2020. Improved crop row detection with deep neural network for early-season maize stand count in UAV imagery. *Computers and Electronics in Agriculture* 178, 105766. <https://doi.org/10.1016/j.compag.2020.105766>.

Pedersen, S.M., Fountas, S., Blackmore, B.S., Gylling, M., Pedersen, J.L., 2004. Adoption and perspectives of precision farming in Denmark. *Acta Agriculturae Scandinavica, Section B — Soil & Plant Science* 54 (1), 2–8. <https://doi.org/10.1080/09064710310019757>.

Peng, J., Manevski, K., Kørup, K., Larsen, R., Andersen, M.N., 2021. Random forest regression results in accurate assessment of potato nitrogen status based on multispectral data from different platforms and the critical concentration approach. *Field Crops Research* 268, 108158. <https://doi.org/10.1016/j.fcr.2021.108158>.

Polimena, S., Pio, G., Cefola, M., Palumbo, M., Ceci, M., Attolico, G., 2024. A novel random forest-based approach for the non-destructive and explainable estimation of ammonia and chlorophyll in fresh-cut rocket leaves. *Information Processing in Agriculture*. <https://doi.org/10.1016/j.inpa.2024.09.002>.

Preite, L., Vignali, G., 2024. Artificial intelligence to optimize water consumption in agriculture: A predictive algorithm-based irrigation management system. *Computers and Electronics in Agriculture* 223, 109126. <https://doi.org/10.1016/j.compag.2024.109126>.

Priyanka, Srivastava, P.K., Rawat, R., 2023. Retrieval of leaf chlorophyll content using drone imagery and fusion with Sentinel-2 data. *Smart Agricultural Technology* 6, 100353. <https://doi.org/10.1016/j.atech.2023.100353>.

R Core Team, 2024. R: a language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>.

Ramos, A.P.M., Osco, L.P., Furuya, D.E.G., Gonçalves, W.N., Santana, D.C., Teodoro, L.P.R., Silva Junior, C.A., Capristo-Silva, G.F., Li, J., Baio, F.H.R., Marcato Junior, J., Teodoro, P.E., Pistori, H.A., 2020. A random forest ranking approach to predict yield in maize with UAV-based vegetation spectral indices. *Computers and Electronics in Agriculture* 178, 105791. <https://doi.org/10.1016/j.compag.2020.105791>.

Richardson, A. J., Wiegand, A., 1977. Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing* 43, 1541-1552. https://www.asprs.org/wp-content/uploads/pers/1977journal/dec/1977_dec_1541-1552.pdf.

Salazar-Reque, I., Arteaga, D., Mendoza, F., Rojas, M.E., Soto, J., Huaman, S., Kemper, G., 2023. Differentiating nutritional and water statuses in Hass avocado plantations through a temporal analysis of vegetation indices computed from aerial RGB images. *Computers and Electronics in Agriculture* 213, 108246. <https://doi.org/10.1016/j.compag.2023.108246>.

Setargie, T.A., Tsunekawa, A., Haregeweyn, N., Tsubo, M., Fenta, A.A., Berihun, M.L., Sultan, D., Yibeltal, M., Ebabu, K., Nzioki, B., Meshesha, T.M., 2023. Random Forest-based gully erosion susceptibility assessment across different agro-ecologies of the Upper Blue Nile basin, Ethiopia. *Geomorphology* 431, 108671. <https://doi.org/10.1016/j.geomorph.2023.108671>.

Shahare, Y.R., Singh, M.P., Singh, S.P., Singh, P., Diwakar, M., 2024. ASUR: Agriculture Soil Fertility Assessment Using Random Forest Classifier and Regressor. *Procedia Computer Science* 235, 1732-1741. <https://doi.org/10.1016/j.procs.2024.04.164>.

Shubhika, S., Patel, P., Singh, R., Tripathi, A., Prajapati, S., Rajput, M.S., Verma, G., Rajput, R.S., Pareek, N., Saratale, G.D., Chawade, A., Choure, K., Vivekanand, V., 2024. Application of artificial intelligence techniques to addressing and mitigating biotic stress in paddy crop: A review. *Plant Stress* 14, 100592. <https://doi.org/10.1016/j.stress.2024.100592>.

Tan, J., Ding, J., Wang, Z., Han, L., Wang, X., Li, Y., Zhang, Z., Meng, S., Cai, W., Hong, Y., 2024. Estimating soil salinity in mulched cotton fields using UAV-based hyperspectral remote sensing and a Seagull Optimization Algorithm-Enhanced Random Forest Model. *Computers and Electronics in Agriculture* 221, 109017. <https://doi.org/10.1016/j.compag.2024.109017>.

Traxler, C., Gaines, T.A., Küpper, A., Luemmen, P., Dayan, F.E., 2023. The nexus between reactive oxygen species and the mechanism of action of herbicides. *Journal of Biological Chemistry* 299 (11), 105267. <https://doi.org/10.1016/j.jbc.2023.105267>.

Tucker, C.J., 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8 (2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0).

Venkataraju, A., Arumugam, D., Stepan, C., Kiran, R., Peters, T., 2023. A review of machine learning techniques for identifying weeds in corn. *Smart Agricultural Technology* 3, 100102. <https://doi.org/10.1016/j.atech.2022.100102>.

Wang, P., Hanif, A.S., Yu, S.-H., Lee, C.-G., Kang, Y.H., Lee, D.-H., Han, X., 2024. Development of an autonomous drone spraying control system based on the coefficient of variation of spray distribution. *Computers and Electronics in Agriculture* 227, 109529. <https://doi.org/10.1016/j.compag.2024.109529>.

Wei, T., Simko, V., 2021. R package 'corrplot': visualization of a correlation matrix. Version 0.92. <https://github.com/taiyun/corrplot>.

Wickham, H., 2016. *ggplot2: elegant graphics for data analysis*. New York: Springer-Verlag. <https://CRAN.R-project.org/package=ggplot2>.

Woebbecke, D.M., Meyer, G.E., Von Bargen, K., Mortensen, D.A., 1995. Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE* 38 (1), 259–269. <https://doi.org/10.13031/2013.27838>.

Yang, M.-D., Hsu, Y.-C., Tseng, W.-C., Tseng, H.-H., Lai, M.-H., 2025. Precision assessment of rice grain moisture content using UAV multispectral imagery and machine

learning. *Computers and Electronics in Agriculture* 230, 109813. <https://doi.org/10.1016/j.compag.2024.109813>.

Yang, Z., Willis, P., Mueller, R., 2008. Impact of Band-Ratio Enhanced AWiFS Image to Crop Classification Accuracy. *Proceeding Pecora* 17, 17. <https://api.semanticscholar.org/CorpusID:212788>.

Zaimes, G.N., Gounaridis, D., Symeonakis, E., 2019. Assessing the impact of dams on riparian and deltaic vegetation using remotely-sensed vegetation indices and Random Forests modelling. *Ecological Indicators* 103, 630–641. <https://doi.org/10.1016/j.ecolind.2019.04.047>.

Zakaluk, R., Ranjan, R.S., 2008. Predicting the leaf water potential of potato plants using RGB reflectance. *Canadian Biosystems Engineering* 50, 7.1–7.12.

Zarco-Tejada, P.J., Berjón, A., López-Lozano, R., Miller, J.R., Martín, P., Cachorro, V., González, M.R., De Frutos, A., 2005. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. *Remote Sensing of Environment* 99 (3), 271–287. <https://doi.org/10.1016/j.rse.2005.09.002>.

Zhou, Y., Liu, C., Wang, J., Zhang, M.-W., Wang, X., Zeng, L.-T., Cui, Y.-P., Wang, H., Sun, X.-L., 2025. Monitoring soil arsenic content in densely vegetated agricultural areas using UAV hyperspectral, satellite multispectral, and SAR data. *Journal of Hazardous Materials* 484, 136689. <https://doi.org/10.1016/j.jhazmat.2024.136689>.

5. CONSIDERAÇÕES FINAIS

Este estudo permitiu a geração de modelos precisos capazes de avaliar a eficácia do controle de plantas daninhas pelo herbicida glyphosate a partir de imagens com sensores RGB obtidas por *smartphone* e por drones, usando índices de vegetação como variáveis de treinamento.

No primeiro artigo, os modelos desenvolvidos foram capazes de prever com alta precisão, com coeficientes de determinação sempre maiores que 90%, o nível de controle de *Urochloa brizantha* pelo glyphosate, a partir das imagens de *smartphone*. Esses modelos apresentaram robustez contra o *overfitting* (apresentando r^2 maior que 90% para as amostras de validação), confirmando seu potencial de uso em novos conjuntos de dados. Os resultados mostraram a possibilidade de popularização da avaliação de controle com uso de dispositivos móveis, com a criação de aplicativos móveis com os modelos.

No segundo artigo, os modelos desenvolvidos também foram capazes de avaliar com sucesso o controle das plantas daninhas pelo glyphosate, a partir das imagens de drone, alcançando r^2 sempre maiores que 90%, para todas as amostras (de treinamento e de validação), independente da altura de voo do drone. Consequentemente, os modelos também foram robustos contra *overfitting* e podem ser aplicados em novos conjuntos de dados. Além disso, o modelo desenvolvido para avaliar o controle independente da altura também alcançou precisão alta, também com r^2 maior que 90% e com alto desempenho nas amostras de validação, o que confirma sua capacidade de generalização. Além disso, esse modelo, por não depender de imagens de uma altura específica, pode ser aplicado em condições mais amplas, em situações nas quais os dados variem em termos de altura e/ou qualidade da imagem, dentro da faixa de voo testada.

O uso de câmeras comuns (RGB) mostrou-se suficiente para os objetivos propostos, tanto para as imagens obtidas por *smartphone* quanto para as obtidas por drone. Isso torna o processo substancialmente mais acessível economicamente, sem a necessidade de câmeras especiais, como as multi e hiperespectrais, geralmente muito caras e inacessíveis para a maioria das pessoas, além de serem mais complexas e difíceis de operar em comparação a câmeras comuns RGB.

É importante dizer que algoritmos de inteligência artificial (IA) demandam alta capacidade de processamento computacional, sendo que, quanto mais dados são

processados, maior o esforço computacional. No caso deste estudo, foi possível processar os dados com tranquilidade. Entretanto, para áreas muito maiores, um maior poder de processamento computacional pode ser necessário.

Futuras pesquisas podem se beneficiar de estudos em áreas de diferentes localidades, aplicação dos modelos com diferentes plantas e herbicidas, e da geração de modelos com outras ferramentas de IA, como redes neurais artificiais (ANN) e máquinas de vetores de suporte (SVM).